

# **TESIS DE MAESTRÍA**

## **SISTEMA DE CONTROL DE MOVIMIENTO SÍSMICO SEMI- ACTIVO CON REDES NEURONALES EN PÓRTICOS 2D**

**AUTOR:**

**MARIO ANDRÉS CABALLERO RUSSI.**

**TUTOR:**

**ANDRÉS FERNANDO GUZMÁN GUERRERO.**



**UNIVERSIDAD DEL NORTE.**

**DEPARTAMENTO INGENIERÍA CIVIL Y AMBIENTAL.**

**MAESTRÍA EN INGENIERÍA CIVIL – ÉNFASIS ESTRUCTURAS.**

**BARRANQUILLA, COLOMBIA.**

**2020.**

## **DEDICATORIA**

Este trabajo es dedicado a Dios, porque me ha demostrado su infinito amor y que sus tiempos son perfectos. También va dedicado a mis padres, que hicieron esfuerzos de todo tipo para que yo consiguiera este título, esto es una pequeña retribución a todo lo que me han dado y enseñado, esto es por ellos y para ellos. A mis hermanos David y María Alejandra, a Mary, a mi novia Suad, a mis amigos y a mis colegas que creyeron en mí. La actitud es tan importante como la aptitud.

## **AGRADECIMIENTOS**

En primer lugar, quiero agradecer a Dios, quién siempre ha estado conmigo en todas las etapas de mi vida, dándome los dones necesarios para poder enfrentar cualquier situación. Doy gracias a mi familia, especialmente a mis padres que siempre me apoyaron y me animaron para obtener este logro, nada de esto hubiera sido posible sin ellos. Agradezco a mis hermanos David y María Alejandra, quienes son mis compañeros de batallas y me hacen mejorar día tras día para ser un gran ejemplo para ellos. A Mary, que se encargó de cuidarme y estar pendiente de mis necesidades. Quiero agradecer a mi novia Suad, que con su amor y sus consejos, me ayudó a retomar el camino adecuado para llegar a esta meta y me acompañó a recorrerlo hasta el final. También agradezco al resto de mi familia por preocuparse por mí. Gracias a mis amigos del colegio, del pregrado y de la maestría, que de diferentes maneras me motivaron a conseguir este título. Agradezco a mi tutor Andrés Guzmán, y a los ingenieros Carlos Barbosa, Jorge Freja, Sebastián García y Oswaldo Meléndez, quienes con su sabiduría, tiempo y dedicación en mi tesis y en mí, me ayudaron a cumplir este objetivo. Gracias a todas las personas que estuvieron involucradas en este proceso.

## **TABLA DE CONTENIDO**

<b>LISTA DE FIGURAS.....</b>	<b>4</b>
<b>LISTA DE TABLAS.....</b>	<b>8</b>
<b>1. RESUMEN.....</b>	<b>9</b>
<b>2. ABSTRACT.....</b>	<b>9</b>
<b>3. INTRODUCCIÓN.....</b>	<b>10</b>
<b>4. HIPÓTESIS DE TRABAJO.....</b>	<b>12</b>
<b>5. OBJETIVOS.....</b>	<b>13</b>
5.1. Objetivo general .....	13
5.2. Objetivos específicos.....	13
<b>6. ANTECEDENTES .....</b>	<b>14</b>
<b>7. MARCO TEÓRICO .....</b>	<b>17</b>
7.1. Análisis de frecuencias.....	17
7.2. Factores de respuesta dinámica. ....	18
7.3. Sistemas dinámicos de uno y varios grados de libertad. ....	22
7.4. Redes neuronales artificiales .....	28
7.5. Sistemas de control.....	48
<b>8. METODOLOGÍA .....</b>	<b>61</b>
8.1. Análisis del dominio de frecuencias.....	61
8.2. Análisis matricial por el método de la rigidez y análisis modal .....	63
8.3. Red neuronal artificial RNA .....	66
8.4. Sistemas de control.....	67
<b>9. RESULTADOS Y DISCUSIÓN.....</b>	<b>69</b>
9.1. Análisis del dominio de frecuencias.....	69
9.2. Análisis matricial por el método de la rigidez y análisis modal .....	83
9.3. Red neuronal artificial RNA .....	94
9.4. Sistema de control .....	117
9.5. Estrategia de control e implementación práctica.....	119
<b>10. CONCLUSIONES.....</b>	<b>122</b>
<b>11. REFERENCIAS .....</b>	<b>124</b>
<b>12. ANEXOS .....</b>	<b>132</b>

## LISTA DE FIGURAS

Fig. 1: Sistema de control semi-activo de tendón de fricción..	16
Fig. 2: Gráficas de factores dinámicos de respuesta de desplazamiento, velocidad y aceleración.	19
Fig. 3: Gráfica logarítmica de relación entre frecuencias y los factores dinámicos de respuesta.	20
Fig. 4: Gráfica logarítmica de la transmisibilidad de fuerzas.	21
Fig. 5: Grados de libertad de desplazamiento, deflexiones y, rotaciones.	23
Fig. 6: Fuerzas presentes en los sistemas dinámicos.	23
Fig. 7: Estructura de dos pisos y dos grados de libertad.	24
Fig. 8: Primer modo de vibración de una estructura de dos pisos y dos grados de libertad.	26
Fig. 9: Segundo modo de vibración de una estructura de dos pisos y dos grados de libertad.	26
Fig. 10: Esquema de una neurona biológica y sus partes en una red neuronal.	29
Fig. 11: Gráfica número de neuronas ocultas vs. tasa de error en datos de prueba.	33
Fig. 12: Gráfica número de épocas de entrenamiento vs. error cuadrático medio.	34
Fig. 13: Diagrama de flujo del proceso de entrenamiento y funcionamiento de las RNA.	34
Fig. 14: Esquema de modelo de GRNN de redes neuronales.	36
Fig. 15: Esquema de modelo de PNN de redes neuronales.	37
Fig. 16: Desempeño del método del descenso del gradiente.	43
Fig. 17: RNA de 4 capas.	45
Fig. 18: Cuadro de flujo del procedimiento backpropagation, corrección $p1$ debido $\Delta p1$ .	46
Fig. 19: Cuadro de flujo del procedimiento backpropagation, corrección de $\Delta w1$ .	46
Fig. 20: Esquema de funcionamiento de los sistemas de control pasivos.	49
Fig. 21: Ejemplos de aislamiento sísmico.	50
Fig. 22: Amortiguador de fricción.	51
Fig. 23: Amortiguador viscoelástico.	51
Fig. 24: Amortiguador de masa sincronizado.	52
Fig. 25: Esquema de funcionamiento de un amortiguador de líquido sincronizado.	53
Fig. 26: Esquema de funcionamiento de los sistemas de control activos.	53
Fig. 27: Esquema de funcionamiento de TMD activo.	54

Fig. 28: Esquema de funcionamiento de actuadores distribuidos en un sistema de combustión. ....	54
Fig. 29: Esquema de funcionamiento de los sistemas de control semi-activos. ....	55
Fig. 30: Ejemplo de dispositivo de control de rigidez. ....	56
Fig. 31: Amortiguador electroreológico. ....	57
Fig. 32: Amortiguador magnetoreológico. ....	58
Fig. 33: Amortiguador de masa sincronizada TMD. ....	59
Fig. 34: Diagrama de flujo de la metodología para esta tesis. ....	61
Fig. 35: Formato de datos de acelerogramas obtenidos del sismo de Tijuana, México. ....	71
Fig. 36: Formato de datos de acelerogramas obtenidos del sismo de Los Santos, Santander, Colombia. ....	71
Fig. 37: Formato de datos de acelerogramas organizados del sismo de Tijuana, México, EE.UU. ....	72
Fig. 38: Formato de datos de acelerogramas organizados del sismo de Los Santos, Santander, Colombia. ....	72
Fig. 39: Gráfica del acelerograma del sismo de Tijuana, México. ....	73
Fig. 40: Gráfica de velocidades del sismo de Tijuana, México. ....	74
Fig. 41: Gráfica de desplazamientos del sismo de Tijuana, México. ....	74
Fig. 42: Gráfica del acelerograma del sismo de Los Santos, Colombia. ....	75
Fig. 43: Gráfica de velocidades del sismo de Los Santos, Colombia. ....	75
Fig. 44: Gráfica de velocidades del sismo de Los Santos, Colombia. ....	76
Fig. 45: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 2.5 s. ....	77
Fig. 46: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 5.0 s. ....	78
Fig. 47: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 10.0 s. ....	78
Fig. 48: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 15.0 s. ....	79
Fig. 49: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 2.5 s. ....	80

Fig. 50: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 5.0 s.....	80
Fig. 51: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 10.0 s.....	81
Fig. 52: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 15.0 s.....	81
Fig. 53: Gráfica de amplitud espectral en función de las frecuencias del sismo de Tijuana, México.....	82
Fig. 54: Gráfica de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia.....	82
Fig. 55: Estructura 2D en estudio. ....	87
Fig. 56: Gráfica de número de pisos vs. masa modal (normalizada) actuante de la estructura inicial. ....	91
Fig. 57: Gráfica de desplazamiento vs. tiempo, de la estructura inicial con el sismo de Tijuana, México.....	91
Fig. 58: Cortante basal actuante vs. tiempo, de la estructura inicial con el sismo de Tijuana, México.....	92
Fig. 59: Momento basal actuante vs. tiempo, de la estructura inicial con el sismo de Tijuana, México.....	92
Fig. 60: Gráfica de desplazamiento vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia.....	93
Fig. 61: Cortante basal actuante vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia.....	93
Fig. 62: Momento basal actuante vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia.....	94
Fig. 63: Esquema inicial planteado para el entrenamiento de la RNA.....	95
Fig. 64: Arquitectura de la configuración 0 de la RNA.....	96
Fig. 65: Error cuadrático medio MSE de la configuración 0. ....	97
Fig. 66: Factor de correlación R de la configuración 0. ....	97
Fig. 67: Proceso de codificación de configuraciones de riostras.....	98
Fig. 68: Nuevo esquema para el entrenamiento de la RNA. ....	99

Fig. 69: Arquitectura de la configuración 1 de la RNA.....	100
Fig. 70: Error cuadrático medio MSE de la configuración 1. ....	100
Fig. 71: Factor de correlación R de la configuración 1. ....	101
Fig. 72: Comparación del error cuadrático medio MSE de la configuración 0 y 1.....	102
Fig. 73: Comparación del factor de correlación R de la configuración 0 y 1.....	102
Fig. 74: Comparación del error cuadrático medio MSE de las configuraciones 1 a 6. ....	105
Fig. 75: Comparación del factor de correlación R de las configuraciones 1 a 6.....	105
Fig. 76: Arquitectura escogida para la RNA. ....	106
Fig. 77: Histograma de errores de predicción de la variable área de riostras de todos los entrenamientos.....	107
Fig. 78: Histograma de errores de predicción de la variable código de riostras de todos los entrenamientos.....	108
Fig. 79: Histograma de errores de predicción de la variable área de riostras del entrenamiento 10. ....	109
Fig. 80: Histograma de errores de predicción de la variable código de riostras del entrenamiento 10. ....	109
Fig. 81: Histograma de número de riostras predichas del entrenamiento 10. ....	110
Fig. 82: Red neuronal artificial para predicción.....	112
Fig. 83: Estructura modificada por sistema de control.....	113
Fig. 84: Gráfica comparativa de número de pisos vs. masa modal actuante (normalizada), de la estructura inicial y la estructura final.....	115
Fig. 85: Gráfica comparativa de desplazamiento vs tiempo, de la estructura inicial y la estructura final. ....	115
Fig. 86: Gráfica comparativa de cortante basal actuante vs tiempo, de la estructura inicial y la estructura final. ....	116
Fig. 87: Gráfica comparativa de momento basal actuante vs tiempo, de la estructura inicial y la estructura final. ....	116
Fig. 88: Diagrama de bloques de la estrategia de control.....	119
Fig. 89: Diagrama de flujo del algoritmo del sistema de control. ....	120
Fig. 90: Código QR para anexos. ....	132

## LISTA DE TABLAS

Tabla 1: Funciones de activación más utilizadas en RNA. ....	30
Tabla 2: Frecuencias predominantes en distintos momentos de tiempo del sismo de Tijuana, México. ....	77
Tabla 3: Frecuencias predominantes en distintos momentos de tiempo del sismo de Los Santos, Santander, Colombia. ....	79
Tabla 4: Factores y niveles del diseño de experimentos factorial $3^8$ .....	84
Tabla 5: Estudio de sensibilidad de factores del diseño de experimentos. ....	84
Tabla 6: Combinaciones de arquitecturas para RNA de 2 capas y resultados de MSE y R. ....	103
Tabla 7: Combinaciones de arquitecturas para RNA de 3 capas y resultados de MSE y R. ....	103



# **SISTEMA DE CONTROL DE MOVIMIENTO SÍSMICO SEMI-ACTIVO CON REDES NEURONALES EN PÓRTICOS EN 2D**

## **1. RESUMEN**

Esta investigación presenta una metodología de control sísmico semi-activo mediante redes neuronales artificiales para predecir la mejor disposición geométrica que se puede utilizar en una estructura plana debido a los efectos de una excitación sísmica predeterminedada. El objetivo final de esta disposición es evitar la resonancia entre la estructura y el sismo causada por una similitud de frecuencias entre ambas partes. El estudio se realiza a pórticos de acero estructural de varios niveles, de 1 a 10 pisos.

Los resultados obtenidos de las redes neuronales artificiales (RNA) determinan el área y la ubicación de las riostras en la estructura iniciando el funcionamiento del sistema de control sísmico semi-activo que ejecuta la decisión calculada y cambia el comportamiento estructural del pórtico mediante riostras que se activan o se desactivan con un mecanismo de amortiguadores magnetoreológicos.

***Palabras claves:** control sísmico semi-activo; redes neuronales artificiales; resonancia; respuesta estructural; amortiguadores magnetoreológicos.*

## **2. ABSTRACT**

This master thesis presents a methodology of semi-active seismic control using artificial neural networks to predict the best structural arrangement that can be used on a portal frame structure, due to the effects of a predetermined seismic excitation. The final objective of this arrangement is to avoid the resonance between the structure and the earthquake caused by a frequency similarity between both parts. The study will be carried out on multi-stories structural steel frames structures, from 1 to 10 floors.

The results obtained from artificial neural networks (ANN) determine the area and the location of the braces in the structure, starting the operation of the semi-active seismic control that executes the calculated decision and changes the structural behavior of the frame structure through braces that are activated or deactivated with a mechanism of magnetorheological dampers.

***Keywords:** semi-active seismic control, artificial neural networks, resonance, structural response, magnetorheological dampers.*

### 3. INTRODUCCIÓN

La ingeniería civil es un área del conocimiento que está en constante actualización y desarrollo de metodologías y teorías que permitan resolver problemáticas comunes a esta disciplina. En los últimos años, con la última actualización del reglamento que rige el análisis, el diseño y la construcción de estructuras en nuestro país, el NSR-10 (AIS, 2010), se ha dado una importancia relevante al estudio de los efectos causados por los movimientos sísmicos y su interacción con las estructuras, para garantizar su correcto funcionamiento.

El título A del NSR-10 presenta los requisitos generales de diseño y construcción sismo-resistente, y explica los parámetros involucrados en el análisis sísmico, como aceleración pico efectiva, coeficientes de amplificación y de importancia, tipo de suelo, y perfil estratigráfico, entre otros, que permiten la constitución de un espectro sísmico (ya sea de aceleración, de velocidad o desplazamiento) como una representación de los impactos que los eventos sísmicos producen en el suelo y se transmiten hacia la estructura en análisis.

Una herramienta que se puede utilizar para el desarrollo de modelos que permitan encontrar un patrón de comportamiento de respuesta de las estructuras debido a un sismo es la estadística. Algunas de las variables de interés pueden ser: máximo desplazamiento lateral, desplazamientos rotacionales, esfuerzo cortante de piso, esfuerzo basal, ductilidad, entre otras (Y.G. Li, F. Fan & H.P. Hong, 2015) . Con los mecanismos que existen actualmente para el registro de sismos, se puede determinar cómo funcionan los sistemas estructurales dinámicos que son sometidos a las cargas y efectos sísmicos. De esta manera, los métodos de análisis y diseño estructural pueden tener una menor incertidumbre en la respuesta estructural respecto a las acciones externas registradas por la instrumentación sísmica.

Para obtener una buena respuesta ante los sismos, es necesario tener una configuración estructural adecuada, acorde a las consideraciones expresadas por Moroni (2014). Esta configuración depende de diversas variables como del sistema estructural, los materiales de construcción, las dimensiones, las secciones y la ubicación de los elementos estructurales, las restricciones y las condiciones especiales arquitectónicas y estructurales que se pueden presentar, los arriostramientos adicionales, entre otros. La modificación de alguna de estas características influye directamente en el comportamiento de la edificación.

Con tantos parámetros interviniendo en la respuesta sísmica de una estructura, regular uno de esos parámetros podría ser significativo para el control total de la edificación. Bajo este concepto, la implementación de un sistema de control toma relevancia.

Las redes neuronales artificiales (RNA), se comenzaron a estudiar por la necesidad de entender el mundo de la computación como si fuese un cerebro humano. Así, un neurofisiólogo y un matemático, McCulloch & Pitts (1943), lanzaron una teoría que permitía el desarrollo de un mecanismo matemático que ejecutaba operaciones lógicas mediante circuitos eléctricos simples que tenían elementos que se comunicaban entre sí. La evolución de las computadoras, trajo muchos avances a las redes neuronales, ampliando su campo de aplicación a áreas del conocimiento como las matemáticas y la ingeniería.

Los sistemas de control, en la ingeniería estructural, han sido utilizados desde finales del siglo XX, cuando Hrovat, Barak, & Rabins (1983) propusieron uno de los primeros sistemas semi-activos para regular las cargas ambientales que actuaban sobre una edificación objeto de su investigación. Desde ese momento, comenzó un desarrollo teórico y matemático importante en esta área de estudio para la concepción y optimización de procesos que permitieran la adaptación de los sistemas de control, a cualquier tipo de necesidad; adaptación que hace referencia a la diversidad de parámetros que se pueden manejar para realizar el control del sistema y del entorno estructural.

Dentro del alcance de esta investigación, se pretende desarrollar una metodología de control que impactará el comportamiento estructural al momento de la ocurrencia de un evento sísmico y que disminuyan los efectos negativos (i.e. desplazamientos máximos, esfuerzos cortantes) que puedan afectar a la edificación, mediante la variación de la rigidez estructural. El parámetro que se desea controlar, en este caso, es la relación entre la frecuencia de vibración del sismo y la frecuencia de vibración de la estructura. Se plantea que este sistema de control sea del tipo semi-activo a través del uso de redes neuronales que regulen la actividad de dispositivos de amortiguamiento magnetoreológico para el funcionamiento del mecanismo de control.

#### **4. HIPÓTESIS DE TRABAJO**

Los efectos de los eventos sísmicos se han convertido en una parte fundamental tanto del análisis como del diseño estructural, puesto que estos eventos sísmicos impactan directamente sobre las estructuras, de tal manera que estas pueden sufrir desde daños leves hasta daños que impliquen el colapso. Así, la modelación de sistemas que permitan un seguimiento al comportamiento estructural de las edificaciones resulta de vital importancia para el funcionamiento de las estructuras.

¿Cómo se verían afectadas las estructuras bajo eventos sísmicos con diversos componentes de magnitud y duración? Y, ¿cómo encontrar un mecanismo que permita controlar el patrón de respuesta de las edificaciones ante la ocurrencia de eventos sísmicos?

Esta investigación se basa en la hipótesis de que las redes neuronales artificiales, que regulan un sistema de control semi-activo, pueden analizar, explicar y determinar una configuración estructural específica cuya respuesta ante un evento sísmico no conlleve a efectos negativos a la edificación.

## **5. OBJETIVOS**

### **5.1. Objetivo general**

- Diseñar un sistema de control sísmico semi-activo basado en redes neuronales artificiales para la regulación del desplazamiento lateral de pórticos 2D ante distintos registros sísmicos, determinando la mejor configuración de arriostramiento posible.

### **5.2. Objetivos específicos**

- Desarrollar un análisis espectral de frecuencias con base en los registros obtenidos como resultado de un evento sísmico.
- Implementar el análisis matricial por el método de la rigidez y el análisis modal de una estructura teniendo en cuenta la configuración y propiedades dinámicas que lo caracterizan.
- Establecer una red neuronal artificial capaz de seleccionar la mejor configuración estructural de una edificación ante los efectos de un sismo.
- Proponer un sistema de control semi-activo que realice modificaciones estructurales a los pórticos para cambiar sus propiedades dinámicas de forma eficaz, segura y fácil.

## 6. ANTECEDENTES

Las redes neuronales artificiales (RNA) han sido una metodología matemática muy útil para encontrar soluciones a problemáticas del análisis y diseño estructural que necesiten cumplir con los requerimientos de las normativas existentes, debido a que el aprendizaje y el entrenamiento correcto de la RNA, permite controlar parámetros como derivas, cuantías de refuerzo y deflexiones. Ahmadi, Moghadas & Lavaei (2008) determinaron dos tipos de RNA: regresión generalizada y ondas de propagación inversa, para predecir con gran precisión, la respuesta dinámica que presenta una estructura predefinida ante los efectos provocados por un sismo.

Pérez & González (2008) desarrollaron una red neuronal artificial para predecir cuáles serían los primeros elementos estructurales del tablero y de las vigas de un puente vehicular que sufrirán daños a flexión si se varían las características de dichos elementos, teniendo como datos de entrada, las diferencias de energías de las deformaciones modales y como datos de salida, la rigidez a flexión resultante de las vigas del puente.

Ahmad, Mat Noor, & Zhang (2009) investigaron sobre nuevas metodologías para mejorar los procedimientos de las redes neuronales artificiales y desarrollaron técnicas que permiten robustecer la modelación y el control de procesos no lineales. Estas técnicas consisten en ensamblar y combinar diferentes tipos de redes neuronales ya establecidas y reentrenarlas para que los parámetros de entrada y salida se comuniquen entre todas las RNA involucradas.

Bojórquez, Tolentino, Yunes & Ruiz (2014) entrenaron una RNA en base al método *backpropagation* para el diseño sismo-resistente óptimo de una edificación en México, tomando una base de datos con 90 configuraciones estructurales diferentes dónde los parámetros constantes del modelo eran las características de los materiales, las variables de entrada de la red neuronal eran la configuración geométrica de la estructura (número de pisos, número de vanos en ambos sentidos y distancia de vanos) y las variables de salida eran las dimensiones de las secciones y la cantidad de refuerzo para las vigas y las columnas.

Arcila, Riveros & Riveros (2014) realizaron un procedimiento de optimización de tamaños de las secciones y el diseño estructural de vigas y columnas que componen el sistema de

resistencia sísmica de una edificación de concreto, tomando como datos de entrada las derivas de cada piso existente, cumpliendo con los límites del NSR-10, y como datos de salida las características del refuerzo de los elementos de pórticos, también con la aplicación de redes neuronales artificiales.

Como se había mencionado anteriormente, los sistemas de control en la ingeniería han evolucionado desde su aparición a finales del siglo pasado hasta el amplio desarrollo que se le ha visto en los últimos años. Ying, Ni & Ko (2005), aplicaron un sistema de control semi-activo óptimo para un sistema no lineal de múltiples grados de libertad. Este sistema de control se implementó en una edificación con el propósito de regular la respuesta de la estructura ante cualquier tipo de cargas.

Pnevmatikos & Gantes han realizado varios estudios con sistemas de control (2004; 2010). En 2004, analizaron la implementación de un sistema de control con el objeto de procesar la información y caracterizar eventos sísmicos ocurridos, para obtener un sistema de detección temprana de ocurrencia de nuevos sismos y disponer el funcionamiento del dispositivo activo de variación de rigidez en riostras. Por otra parte, en el 2010, se centraron en crear un algoritmo para explicar detalladamente el funcionamiento, el comportamiento y el rendimiento del uso de los sistemas de control estudiados en la investigación anteriormente mencionada.

Guzmán et al., (2017) desarrollaron un sistema de control semi-activo con control difuso para también evitar el efecto de la resonancia en las estructuras, en el que un algoritmo era capaz de determinar y elegir, en tiempo real, qué configuración estructural debería tener la estructura para tener un adecuado comportamiento ante un sismo, a través de la activación o desactivación de riostras predeterminadas.

Jung, Choi, Spencer & Lee (2006) realizaron varios algoritmos que conforman un sistema de control semi-activo con el fin de modelar el aislamiento de la base de una estructura a través de amortiguadores magnetoreológicos. Los métodos que se programaron son los siguientes: control optimizado, control optimizado recortado, máxima disipación de energía, fricción modulada homogénea y control de lógica difusa.

Bitaraf, Hurlebaus & Barroso (2012) también estudiaron la posibilidad de utilizar amortiguadores magnetoreológicos para proteger estructuras de los efectos provocados por

eventos sísmicos. Para tal fin, determinaron dos sistemas de control semi-activo: en el primer sistema de control se usó el método simple adaptativo, que consiste en controlar el sistema dependiendo de la respuesta del modelo propuesto; y en el segundo sistema de control se usó el método difuso que permite evaluar la relación entre los parámetros de entrada y de salida mediante la verificación de parámetros como derivas y aceleraciones máximas registradas en los modelos analizados.

Pardo-Varela & de la Llera (2015) se interesaron por el desarrollo de un sistema de control que pudiera trabajar de forma pasiva y semi-activa. Un amortiguador de fricción piezoeléctrico fue útil para esta investigación cuyo objetivo era controlar la respuesta sísmica de estructuras a gran escala. Este dispositivo piezoeléctrico reacciona debido a un sistema de sujeción rígido y al actuar, aplica una fuerza normal variable sobre las superficies de contacto adyacentes.

Garrido, Curadelli & Ambrosini (2016), con el propósito de disminuir los efectos negativos de las vibraciones (vibraciones de piso, ruidos, mal funcionamiento de instrumentos sensoriales deterioro estructural, colapso) que se producen en cualquier estructura, implementaron un sistema de control semi-activo con un tendón de fricción, que se compone de un amortiguador de fricción y un resorte auxiliar que está unido a la estructura con un cable (Fig. 1).




Fig. 1: Sistema de control semi-activo de tendón de fricción. Fuente: *Experimental and theoretical study of semi-active friction tendons.* (Garrido et al., 2016).



## 7. MARCO TEÓRICO

En este capítulo se presenta toda la información correspondiente a cada uno de los temas que abarcan esta tesis. Se realiza una revisión literaria que explica y detalla teorías, metodologías, fórmulas, consideraciones y demás, para el entendimiento de la investigación realizada.

### 7.1. Análisis de frecuencias

Geológicamente, según Herráiz (1997), los terremotos o sismos son el resultado de un proceso de deformación elástica en una zona de la corteza terrestre, que cuando se supera la resistencia del suelo, se genera una liberación súbita de energía elástica en forma de ondas que se propagan por el terreno. Estas ondas de energía son capaces de llegar hasta la superficie terrestre, percibirse y afectar lo que esté sobre el suelo, dependiendo de su magnitud y su frecuencia. Los sismos no siguen ningún patrón de comportamiento, por lo que las cargas que generan sobre los cuerpos que están en contacto con la superficie terrestre se categorizan como cargas no periódicas y arbitrarias.

A pesar de esto, se pueden realizar varios análisis a los eventos sísmicos para intentar clasificar las ondas generadas y sus propiedades físicas, tales como dirección de propagación, velocidad de propagación, formas de vibración, entre otras. Dentro de los métodos que existen para el estudio de los sismos, se encuentra el análisis de dominio de frecuencias, que consiste en determinar cuál es la frecuencia o conjunto de frecuencias predominantes de las ondas sísmicas durante el tiempo que dura el sismo. Para tal fin, se utiliza el concepto matemático de las transformadas de Fourier.

Clough & Penzien (1975) explican las consideraciones que se deben tener en cuenta para aplicar la teoría de Fourier. Inicialmente, se considera que  $p(t)$  es una carga periódica para aplicar la metodología de las transformadas de Fourier, aunque realmente sea arbitraria. Además, se asume que el periodo de la carga tiende a infinito ( $T_p \rightarrow \infty$ ), así mismo, ocurre un incremento de frecuencia natural infinitesimal  $\Delta\omega \rightarrow d\omega$ , y se deben convertir las frecuencias naturales del sistema, que son discretas, en una función continua de frecuencias (Ec. 1 y Ec. 2).

$$p(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} P(\omega) e^{i\omega t} d\omega \quad \text{Ec. 1}$$

$$P(\omega) = \int_{-\infty}^{\infty} p(t) e^{-i\omega t} dt \quad \text{Ec. 2}$$

La Ec. 1 y la Ec. 2 corresponden a las transformadas de Fourier: la transformada inversa y la transformada directa, respectivamente. La respuesta de desplazamiento que se obtiene de este análisis se muestra en la Ec. 3.

$$u(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} H(\omega) P(\omega) e^{i\omega t} d\omega \quad \text{Ec. 3}$$

$$H(\omega) = \frac{1}{k} \left[ \frac{1}{(1-\beta^2) + i(2\xi\beta)} \right] = \frac{1}{k} \left[ \frac{(1-\beta^2) - i(2\xi\beta)}{(1-\beta^2)^2 + (2\xi\beta)^2} \right] \quad \text{Ec. 4}$$

La Ec. 4 depende de 3 parámetros dinámicos del sistema:  $k$  (rigidez de la estructura),  $\beta$  (relación entre la frecuencia real y la frecuencia natural de la estructura) y  $\xi$  (coeficiente de amortiguamiento de la estructura).

## 7.2. Factores de respuesta dinámica.

Cuando un sistema físico sufre un cambio de estado, las variables que explican este comportamiento son el desplazamiento, la velocidad y la aceleración. Si este cambio de estado es provocado por una carga armónica o una excitación periódica (Ec. 5), se producen sendos factores de respuesta de desplazamiento, velocidad y aceleración que afectan la amplitud de estos parámetros en el sistema físico. En el estado estable (Chopra, 2001), se define que el factor de respuesta de desplazamiento en la Ec. 6.

$$\frac{u(t)}{p_o / k} = R_d \sin(\omega t - \phi) \quad \text{Ec. 5}$$

$$R_d = \frac{u(t)k}{p_o \sin(\omega t - \phi)} \quad \text{Ec. 6}$$

Dónde  $u(t)$  es el desplazamiento del sistema en el tiempo  $t$ ,  $p_o$  la fuerza externa inicial aplicada al sistema,  $R_d$  es el factor de respuesta de desplazamiento,  $\omega$  es la frecuencia de la

fuerza externa y  $\phi$  es el ángulo de desfase. Las relaciones entre el factor de respuesta de desplazamiento ( $R_d$ ) y los factores de respuesta de velocidad ( $R_v$ ) y de aceleración ( $R_a$ ), se presentan en Ec. 7 y Ec. 8.

$$R_v = \frac{\omega}{\omega_n} R_d \quad \text{Ec. 7}$$

$$R_a = \left( \frac{\omega}{\omega_n} \right)^2 R_d \quad \text{Ec. 8}$$

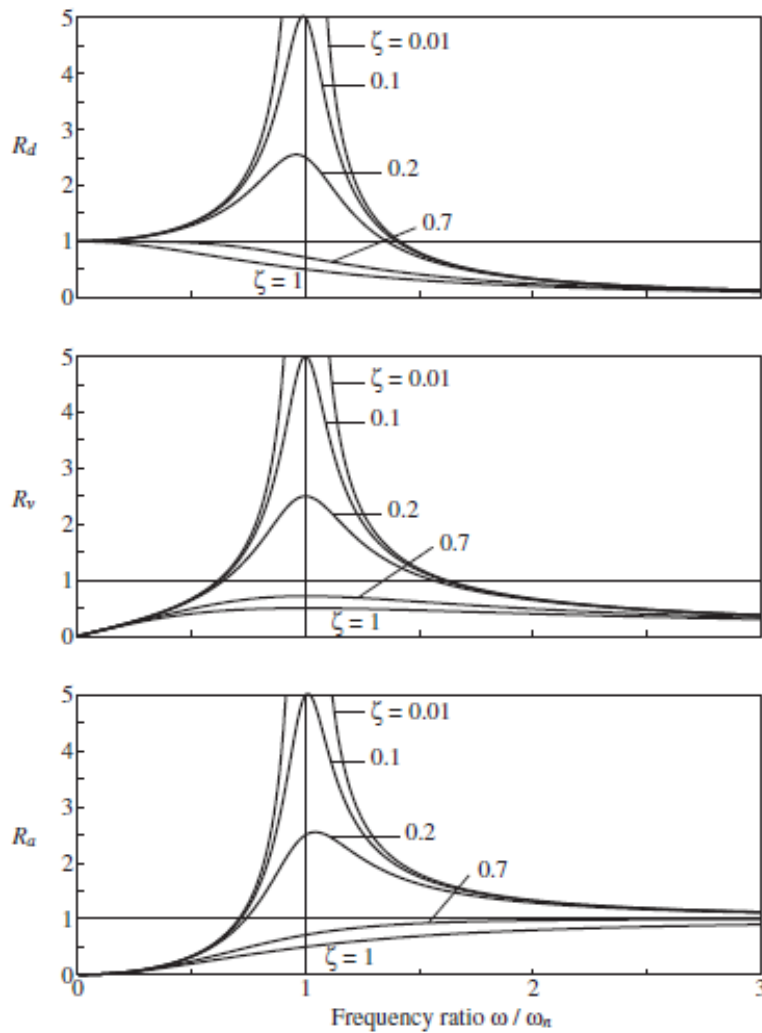


Fig. 2: Gráficas de factores dinámicos de respuesta de desplazamiento, velocidad y aceleración.  
Fuente: Dynamics of structures: theory and applications to earthquake engineering. (Chopra, 2001).

De la Fig. 2, se puede observar cómo influye el amortiguamiento de la estructura en la determinación de los coeficientes de amplificación de desplazamiento, de velocidad y de aceleración. Por las relaciones que se pueden determinar de Ec. 7 y Ec. 8, se puede obtener la Fig. 3, en escala logarítmica, en la cual se muestra la interacción del cociente entre la frecuencia de la fuerza externa y la frecuencia natural de la estructura y los distintos factores de respuesta, dependiendo al porcentaje de amortiguamiento del sistema.




Fig. 3: Gráfica logarítmica de relación entre frecuencias y los factores dinámicos de respuesta.  
Fuente: *Dynamics of structures: theory and applications to earthquake engineering*. (Chopra, 2001).

Con los factores dinámicos de respuesta definidos, aparecen dos conceptos asociados que permiten un mejor análisis para los sistemas físicos que experimentan cargas externas: la transmisibilidad de fuerzas y, las frecuencias y respuestas resonantes.

Según Clough & Penzien (1975), la transmisibilidad de fuerza es la relación entre la máxima fuerza en la base ( $F_{máx}$ ) y la amplitud de la fuerza aplicada ( $p_o$ ). Matemáticamente esto se representa en la Ec. 9.

$$TR = \frac{F_{m\acute{a}x}}{P_0} = \left( \frac{1 + [2\xi(\omega / \omega_n)]}{[1 - (\omega / \omega_n)^2]^2 + [2\xi(\omega / \omega_n)]^2} \right)^{1/2} \quad \text{Ec. 9}$$

La transmisibilidad de la fuerza que resulta del cociente entre la frecuencia de la fuerza y la frecuencia natural de la estructura, dependiendo del coeficiente de amortiguamiento, se observa en la Fig. 4.

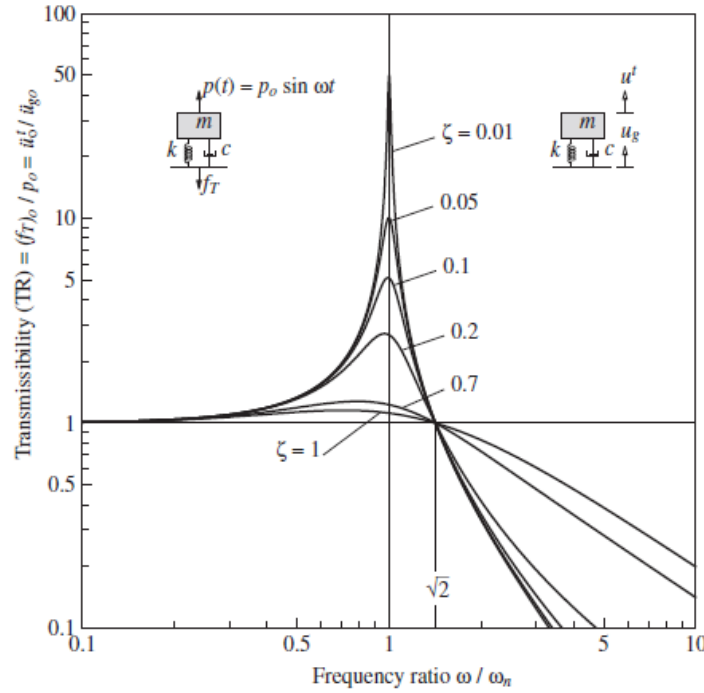


Fig. 4: Gráfica logarítmica de la transmisibilidad de fuerzas.

Fuente: *Dynamics of structures: theory and applications to earthquake engineering*. (Chopra, 2001).

Por otra parte, las frecuencias resonantes se definen como las frecuencias de la fuerza en la que se produce la mayor amplitud de respuesta. Las frecuencias resonantes también se analizan a partir del desplazamiento, velocidad y desplazamiento (Ec. 10, Ec. 11 y Ec. 12).

$$\omega_{dRes} = \omega_n \sqrt{1 - 2\xi^2} \quad \text{Ec. 10}$$

$$\omega_{vRes} = \omega_n \quad \text{Ec. 11}$$

$$\omega_{aRes} = \omega_n / \sqrt{1 - 2\xi^2} \quad \text{Ec. 12}$$

Debido a que las frecuencias resonantes únicamente dependen de la frecuencia natural  $\omega_n$  y el amortiguamiento del sistema  $\xi$ , que son parámetros dinámicos básicos de las estructuras, los factores de respuesta resonantes también se pueden expresar en Ec. 13, Ec. 14 y Ec. 15.

$$R_{dRes} = \frac{1}{2\xi\sqrt{1-\xi^2}} \quad \text{Ec. 13}$$

$$R_{vRes} = \frac{1}{2\xi} \quad \text{Ec. 14}$$

$$R_{aRes} = \frac{\sqrt{1-\xi^2}}{2\xi} \quad \text{Ec. 15}$$

Cabe resaltar que en la 4ª edición del libro “*Dynamics of structures*” de Chopra (2001), que se tomó como referencia de esta tesis, se encontró un error que consistía en que los factores de respuesta resonantes de desplazamiento  $R_{dRes}$  y de aceleración  $R_{aRes}$  tenían la misma fórmula. Se realizó la deducción matemática a partir de la relación entre las frecuencias resonantes  $\omega_{dRes}$ ,  $\omega_{vRes}$ , y  $\omega_{aRes}$ , y los factores de respuesta resonantes  $R_{dRes}$  y  $R_{vRes}$ , para calcular  $R_{aRes}$ , tal y como se muestra en la Ec. 15.

### 7.3. Sistemas dinámicos de uno y varios grados de libertad.

La dinámica es una rama de la física que permite describir el cambio, de estado físico y/o de posición, que experimenta un sistema en un tiempo especificado. Esta descripción se puede expresar en ecuaciones que representan el comportamiento del sistema y los factores que influyen en dicho comportamiento. En la dinámica existen dos campos principales: cinemática y la cinética. La primera estudia la geometría del movimiento, relacionado con el desplazamiento, la velocidad, la aceleración y el tiempo; y la segunda estudia la relación entre las fuerzas que actúan sobre un cuerpo, la masa del cuerpo y su movimiento (García, 1998).

Grados de libertad es uno de los conceptos más importantes dentro del análisis dinámico de cualquier cuerpo físico, sistema y/o estructura. Paz & Kim (2019) definen este concepto como el número de variables independientes que se necesitan para describir la

configuración o la posición de un sistema en cualquier momento de tiempo. Estas variables pueden representar desplazamientos, deflexiones o rotaciones (Fig. 5).




Fig. 5: Grados de libertad de desplazamiento, deflexiones y, rotaciones.

Fuente: *Structural dynamics: Theory and computation*. (Paz & Kim, 2019).

Definiendo esto, la expresión matemática fundamental que explica el movimiento de cualquier cuerpo físico (García, 1998), se presenta en la Ec. 16.

$$m\ddot{u} + c\dot{u} + ku = p(t) \quad \text{Ec. 16}$$

Los términos  $m$  y  $\ddot{u}$  de esta ecuación corresponden a la masa y la aceleración del sistema, conformando así la fuerza inercial del cuerpo; los siguientes dos términos ( $c$  y  $\dot{u}$ ) son el amortiguamiento y la velocidad del sistema, que conforman la fuerza de amortiguamiento; y los dos últimos términos ( $k$  y  $u$ ) son la rigidez de un elemento de restitución y el desplazamiento que tiene el cuerpo, conformando la fuerza elástica. Del lado derecho de la ecuación  $p(t)$  está la fuerza externa que experimenta el sistema dinámico y que hace que el sistema experimente movimiento (Fig. 6). Esta fuerza puede ser de diferentes tipos: puntuales, distribuidas, periódicas, no periódicas, sinusoidales, arbitrarias, entre otras.




Fig. 6: Fuerzas presentes en los sistemas dinámicos.

Fuente: *Chapter 1 – Part A Dynamic Loads, Degrees of Freedom, Newton and D'Alembert Methods for Deriving SDOF EOM*. (Symans, 2008).

Connor & Faraji (2016) presentan diferentes métodos para resolver los sistemas estáticos y dinámicos de distintos tipos de estructuras a través de las ecuaciones de equilibrio (Ec. 16). Uno de ellos es el análisis matricial por el método de la rigidez, el cual consiste en definir los grados de libertad a lo largo de diversos nodos y elementos de la estructura, en términos de desplazamientos, deflexiones y rotaciones que corresponden a los tipos de fuerzas (inercia, amortiguamiento y rigidez) que experimenta el sistema. Esto se resuelve matemáticamente a través de las matrices que representan las masas, los amortiguamientos y las rigideces que caracterizan dinámicamente a la estructura en análisis.

Hay que resaltar que este método funciona bajo ciertas condiciones idealizadas de las estructuras, y son referidas por Chopra (2001).

- Las vigas y el sistema de piso son infinitamente rígidas a la flexión.
- Las vigas y las columnas no sufren de deformación axial.
- La rigidez de las columnas no es afectada por la carga axial actuante.
- Las rotaciones de los nodos se desprecian.
- La masa está uniformemente distribuida en toda la estructura.
- La disipación de energía de la estructura es mediante un mecanismo lineal de amortiguamiento viscoso.
- Los grados de libertad que se tienen en cuenta son los desplazamientos laterales de las columnas en cada piso, los cuales son iguales para las columnas del mismo piso.

A las estructuras con las consideraciones mencionadas, se les llama edificios de cortante idealizados y el ejemplo que muestra Chopra (2001) para el análisis de este tipo de estructuras es el mostrado en la Fig. 7.




Fig. 7: Estructura de dos pisos y dos grados de libertad.

Fuente: Dynamics of structures. (Chopra, 2001).



Resolviendo la Ec. 16 bajo el método del análisis matricial por el método de la rigidez, se obtiene la expresión matemática descrita por la Ec. 17.

$$\begin{bmatrix} m_1 & 0 \\ 0 & m_2 \end{bmatrix} \begin{bmatrix} \ddot{u}_1 \\ \ddot{u}_2 \end{bmatrix} + \begin{bmatrix} c_1 + c_2 & -c_2 \\ -c_2 & c_2 \end{bmatrix} \begin{bmatrix} \dot{u}_1 \\ \dot{u}_2 \end{bmatrix} + \begin{bmatrix} k_1 + k_2 & -k_2 \\ -k_2 & k_2 \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = p(t) \quad \text{Ec. 17}$$

Este es el sistema de matrices que expresa el comportamiento dinámico del ejemplo propuesto en la Fig. 7.

Otra propiedad que poseen todos los sistemas dinámicos, es el periodo natural  $T_n$ , que corresponde al tiempo que necesita una estructura para realizar una oscilación o un ciclo de movimiento y depende de la rigidez ( $k$ ) y la masa ( $m$ ) del sistema (Ec. 18).

$$T_n = \sqrt{\frac{k}{m}} \quad \text{Ec. 18}$$

Por otra parte, la frecuencia natural  $f_n$ , se define como el inverso del periodo natural y representa el número de oscilaciones o ciclos de movimiento que se pueden realizar por unidad de tiempo (Ec. 19).

$$f_n = \frac{\#ciclos}{tiempo} = \sqrt{\frac{m}{k}} = \frac{1}{T_n} \quad \text{Ec. 19}$$

La frecuencia natural circular  $\omega_n$  es el número de radianes que el sistema dinámico realiza por unidad de tiempo (Ec. 20).

$$\omega_n = 2\pi f_n = \frac{2\pi}{T_n} \quad \text{Ec. 20}$$

De la Ec. 16, una de las variables de mayor estudio es el desplazamiento  $u$  del sistema. Este desplazamiento varía según las condiciones iniciales de movimiento que tenga la estructura dependiendo si la estructura experimenta vibración libre, excitación armónica libre, excitación armónica amortiguada, excitación arbitraria, excitación de paso o excitación de pulso. Independientemente al tipo de la carga que genera el movimiento en el sistema, el desplazamiento se puede describir matemáticamente en función de la frecuencia natural circular (Ec. 21).

$$u(t) = A \sin(\omega_n t) + B \cos(\omega_n t)$$

Ec. 21

Además del análisis matricial por el método de la rigidez, el análisis modal también describe las características dinámicas de una estructura. García (1998) describe este método como una solución que permite convertir el sistema de ecuaciones diferenciales que describe el equilibrio de los grados de libertad, en un conjunto de ecuaciones independientes.

Los modos de vibración, que caracterizan el análisis modal, corresponden a la respuesta dinámica si se excita la estructura en vibración libre por cada grado de libertad considerado. Para el ejemplo de la Fig. 7, se tienen dos modos de vibración representados en la Fig. 8 y en la Fig. 9.




Fig. 8: Primer modo de vibración de una estructura de dos pisos y dos grados de libertad.

Fuente: Dynamics of structures. (Chopra, 2001).




Fig. 9: Segundo modo de vibración de una estructura de dos pisos y dos grados de libertad.

Fuente: Dynamics of structures. (Chopra, 2001).

Las figuras Fig. 8 y Fig. 9 muestran el comportamiento dinámico de la estructura con parámetros de rigidez  $k$ , masa  $m$ , y grados de libertad de desplazamiento  $u_1$  y  $u_2$ , debido a los modos de vibración  $\phi_1$  y  $\phi_2$  por cada piso del pórtico en estudio. Se puede observar la deflexión de cada grado de libertad en los instantes de tiempo  $a$ ,  $b$ ,  $c$ ,  $d$  y  $e$ , y las coordenadas modales  $q_1(t)$  y  $q_2(t)$  durante un número de periodos determinados.

Para calcular las frecuencias naturales y los modos de vibración de las estructuras, se puede analizar el desplazamiento de la vibración libre (sin amortiguamiento, Ec. 22), con la definición de  $u(t)$  según la Ec. 23.

$$m\ddot{u} + ku = 0 \quad \text{Ec. 22}$$

$$u(t) = q_n(t)\phi_n \quad \text{Ec. 23}$$

Dónde  $q_n(t)$  se expresa de acuerdo a la Ec. 24.

$$q_n(t) = A_n \cos(w_n t) + B_n \sin(w_n t) \quad \text{Ec. 24}$$

Reemplazando la Ec. 24 en la Ec. 23, se obtiene la Ec. 25.

$$u(t) = \phi_n (A_n \cos(w_n t) + B_n \sin(w_n t)) \quad \text{Ec. 25}$$

Sustituyendo la Ec. 25 en la Ec. 22, resulta la Ec. 26, que se reescribe matemáticamente mediante Ec. 27 y Ec. 28.

$$[-w_n^2 m \phi_n + k \phi_n] q_n = 0 \quad \text{Ec. 26}$$

$$k \phi_n = w_n^2 m \phi_n \quad \text{Ec. 27}$$

$$[k_n - w_n^2 m] \phi_n = 0 \quad \text{Ec. 28}$$

De la Ec. 28 se pueden concluir dos soluciones: la primera corresponde a  $\phi_n=0$ , la cual no tiene sentido físico porque representaría un sistema sin movimiento; o la segunda que equivaldría a que  $k_n - w_n^2 m = 0$ , la cual sí tiene una solución matemática posible. A esta situación, se le llama el problema de los valores propios y el cual permite calcular cada uno de los modos de vibración (Ec. 29).

$$\det[k_n - w_n^2 m] = 0 \quad \text{Ec. 29}$$

El resultado de la Ec. 29 es una matriz  $\phi$  denominada matriz modal que agrupa los modos de vibración correspondientes a las diferentes frecuencias naturales de la estructura con relación a cada uno de los grados de libertad definidos. Estos modos de vibración cumplen con condiciones de ortogonalidad para la rigidez del pórtico de acuerdo con la Ec. 30.

$$\phi_n^T k \phi_r = 0 \quad \text{Ec. 30}$$

Resolviendo de la misma manera el problema de los valores propios, se obtiene la rigidez modal  $K_n$  de la estructura (Ec. 31).

$$K_n = \phi_n^T k \phi_n \quad \text{Ec. 31}$$

De la misma forma, la ortogonalidad de los modos de vibración se puede aplicar a los parámetros de masa y de amortiguamiento para calcular la masa modal  $M_n$  (Ec. 32) y el amortiguamiento modal  $C_n$  (Ec. 33) de la estructura.

$$M_n = \phi_n^T m \phi_n \quad \text{Ec. 32}$$

$$C_n = \phi_n^T c \phi_n \quad \text{Ec. 33}$$

Con Ec. 31, Ec. 32 y Ec. 33, se procede a reemplazar en la Ec. 16 para obtener la solución del sistema de vibración libre con amortiguamiento (Ec. 34).

$$M_n \ddot{q}(t) + C_n \dot{q}(t) + K_n q(t) = p(t) \quad \text{Ec. 34}$$

#### 7.4. Redes neuronales artificiales

Para hablar de las redes neuronales en la ingeniería, primero se debe contextualizar la analogía a la cual hace referencia. Las neuronas son células del sistema nervioso (Fig. 10) cuya función principal es generar y transmitir impulsos eléctricos, también llamados impulsos nerviosos, que llevan un mensaje para que se cumpla alguna orden en cualquier parte del cuerpo de un organismo. Estos impulsos nerviosos llegan a las neuronas por las dendritas, pasan por el soma (cuerpo) dónde se procesa la información, y se dirigen hacia el axón para que dicha información llegue a otra neurona a través de la sinapsis. Al conjunto de neuronas que se comunican entre sí se le conoce como red neuronal.




Fig. 10: Esquema de una neurona biológica y sus partes en una red neuronal.

Fuente: *Introduction to artificial intelligence*. (Ertel, 2017).

Dayhoff & DeLeo (2001) definen las redes neuronales artificiales (RNA) como una metodología computacional que realiza un análisis multifactorial. Los modelos de RNA tienen capas con nudos computacionales simples que funcionan como elementos aditivos no lineales. Estos nodos están interconectados por líneas de conexión que tienen ponderación en su función, ponderación que se ajusta cuando se presenta la información a la RNA durante un proceso de “entrenamiento”.

Las partes de las redes neuronales artificiales que permiten su correcto funcionamiento, según Brío & Molina (2001), son las siguientes:









- **Variables de entrada y salida:** Las variables con las que las RNA realiza su metodología matemática pueden ser binarias (digitales) o continuas (analógicas). Para clasificar las neuronas estándar, se tiene en cuenta la característica de los parámetros de salida: si la salida sólo puede tomar valores de 0 o 1, se considera neurona tipo McCulloch-Pitts; si sólo puede tomar valores de -1 o +1, se considera neurona tipo Ising; y, si puede tomar diversos valores dentro de un intervalo determinado se considera neurona tipo Potts.
- **Regla de propagación:** Utilizando los valores de entrada  $x$  y los pesos específicos (sinápticos)  $w_{ij}$  de las funciones que intervienen en la RNA, se puede calcular el potencial postsináptico  $h_i$  de la neurona. La regla de propagación más habitual es la lineal (Ec. 35), que resulta ser la suma ponderada de los datos de entrada y su interacción con los pesos sinápticos o sesgos  $b_{ij}$ .


$$h_i(t) = \sum_i w_{ij} * x + b_{ij} \quad \text{Ec. 35}$$

- **Función de activación:** Esta función de activación determina el estado actual de la neuronal  $a_i(t)$  a partir del peso postsináptico  $h_i(t)$  y del estado anterior  $a_i(t-1)$ . La función de desempeño o de transferencia, como también se le conoce, generalmente es determinista, monótona creciente y continua, y se recomienda que sea derivable. Demuth, Hagan, Beale & De Jesús (2014) clasifican las funciones de activación más importantes que se utilizan para los modelos de RNA (Tabla 1).

*Tabla 1: Funciones de activación más utilizadas en RNA.*

*Fuente: Neural Network Design. (Demuth et al., 2014).*

Función	Condiciones	Ícono
Escalonada.	$n < 0, a = 0$ $n \geq 0, a = 1$	
Escalonada simétrica.	$n < 0, a = -1$ $n \geq 0, a = +1$	
Lineal.	$n = a$	
Lineal saturada.	$n < 0, a = 0$ $0 \leq n \leq 1, a = n$ $n > 1, a = 1$	
Lineal saturada simétrica.	$n < -1, a = -1$ $-1 \leq n \leq 1, a = n$ $n > 1, a = 1$	
Sigmoide logarítmica.	$a = \frac{1}{1 + e^{-n}}$	
Sigmoide tangente hiperbólica.	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Lineal positiva.	$n < 0, a = 0$ $n \geq 0, a = n$	

Función	Condiciones	Ícono
Competitiva.	Neuronas con mayor $n$ , $a = 1$ Otras neuronas, $a = 0$	

Se puede observar que las funciones de activación, que se muestran en la Tabla 1, tienen comportamientos diferentes con dominios que dependen del intervalo en donde se encuentre la variable  $n$ , que es la variable de entrada de la red neuronal. El tipo de función de activación determina la clasificación del tipo de las neuronas.

- **Función de salida:** Esta función es la que da la salida global de la neurona en función de su estado de activación actual  $a_i(t)$ . Generalmente la función de salida es la identidad, donde  $f(x) = x$  y resulta que la función de activación es la misma función de salida.

Existen otras partes que componen la red neuronal como lo son los métodos de procesamiento y los hiperparámetros. Los métodos de procesamiento hacen referencia a todos las funciones matemáticas que permiten el funcionamiento de la red, tal y como son la función de activación, anteriormente mencionada, la función de aprendizaje (que determina si la RNA tiene un aprendizaje supervisado o no supervisado), la función de entrenamiento (que calcula cuáles son los pesos sinápticos y los sesgos de cada neurona) y la función de pérdidas (que calcula la diferencia entre el resultado predicho por la RNA y el valor real de los datos de prueba) (Skansi, 2018). Los hiperparámetros corresponden a las variables que regulan el diseño y el rendimiento del modelo de la red neuronal. Dentro de estos hiperparámetros se encuentran el número de capas ocultas, el número de neuronas por capa, la tasa de aprendizaje  $\alpha$ , el factor de decaimiento del gradiente  $k$ , la proporción de la validación cruzada y los factores de regularización  $\beta$ .

En el estudio de las redes neuronales artificiales, Aggarwal (2018) expresa que la elección de la función de activación (Tabla 1) es una parte crítica en el diseño de las RNA. Esta elección se basa en qué tipo de variable se desea predecir. Por ejemplo, si las variables de salida que se quieren obtener son números reales, se aconseja utilizar la función lineal, lineal saturada, lineal escalonada o lineal positiva como función de activación. En otros

casos en dónde las variables de salida son decisiones binarias, se deben usar la función escalonada, sigmoide logarítmica, sigmoide tangente hiperbólica o competitiva.

Además, se enfatiza que la importancia de la elección de la función de costo del error también depende del tipo de las variables de salida. Para variables que representan decisiones binarias y valores reales, se utiliza una función de costo conocida como regresión logarítmica (Ec. 36), en dónde se evalúan los valores observados  $y$  y los valores predichos  $\hat{y}$  de la RNA.

$$L = \log(1 + \exp(-y \cdot \hat{y})) \quad \text{Ec. 36}$$

Para variables que clasifiquen resultados y variables discretas, se usa una función de costo conocida como entropía cruzada (Ec. 37), en dónde se analiza únicamente el valor predicho  $\hat{y}_r$  según cada categoría determinada en la red neuronal.

$$L = -\log(\hat{y}_r) \quad \text{Ec. 37}$$

Kubat (2017) plantea 3 situaciones problemas “arquitectónicos” de configuración de las redes neuronales artificiales, los cuales pueden causar que una RNA sea poco flexible o poco acertada ante datos diferentes a los datos de entrenamiento, que la RNA tenga una región de decisión muy compleja, que los procesos iterativos de entrenamiento queden atascados en un valor mínimo local, que la red neuronal tenga un costo computacional muy grande con respecto al tamaño de la RNA o que los resultados de la red se estén sobreajustando a los datos de entrenamiento usados. Estos efectos negativos se evitan con las siguientes observaciones:

- Rendimiento vs. tamaño de la red: Suponiendo que la información disponible para la red neuronal se divide en dos partes iguales, una para el entrenamiento y otra para la comprobación, se considera que el entrenamiento se hace varias veces con redes neuronales que tengan diferentes números de capas y neuronas ocultas. Este entrenamiento se realiza hasta que se observe que la tasa de error de los datos de entrenamiento no disminuye, y en ese momento es en dónde se calcula la tasa de error en los datos de prueba. Así, resulta más importante tener un buen rendimiento en el entrenamiento de la red que una gran base de datos de información para probar la red.
- Número óptimo de neuronas: Si una red neuronal posee pocas neuronas en sus capas ocultas, la RNA tiene una tasa de error muy alta con los datos de prueba y es posible



que el entrenamiento esté atascado en un valor mínimo local. Por el contrario, una RNA con muchas neuronas en sus capas ocultas es vulnerable al sobreajuste de los datos de entrenamiento, provocando que aumente la tasa de error de los datos de prueba (Fig. 11).




Fig. 11: Gráfica número de neuronas ocultas vs. tasa de error en datos de prueba.

Fuente: *An introduction to machine learning*. (Kubat, 2017).

Lo descrito anteriormente se observa en la Fig. 11, aunque el número exacto de neuronas ocultas que cumple con el mínimo error en los datos de prueba depende de la complejidad de los datos de entrenamiento.

– Búsqueda del tamaño apropiado: Kubat (2017) propone un algoritmo para determinar el tamaño óptimo de una RNA. Este algoritmo se resume en los siguiente 4 pasos: comenzar el proceso de entrenamiento con una red neuronal muy pequeña (por ejemplo 5 neuronas), entrenar esa red neuronal hasta que el error cuadrático medio del proceso disminuya y se establezca en un valor mínimo, aumentar levemente el número de neuronas (por ejemplo 3 neuronas adicionales) con sus pesos sinápticos aleatorios para entrenar la red nuevamente, y seguir los pasos 2 y 3 hasta que la adición de neuronas no resulte en una mejora significativa del error obtenido (Fig. 12).




Fig. 12: Gráfica número de épocas de entrenamiento vs. error cuadrático medio.

Fuente: *An introduction to machine learning.* (Kubat, 2017).

Siguiendo con la recomendaciones prácticas, Demuth et al. (2014) muestran algunos problemas que ocurren en las redes neuronales artificiales y a partir de eso da recomendaciones para el diseño de la red. El autor presenta un diagrama de flujo para el proceso de entrenamiento y funcionamiento de la RNA (Fig. 13).

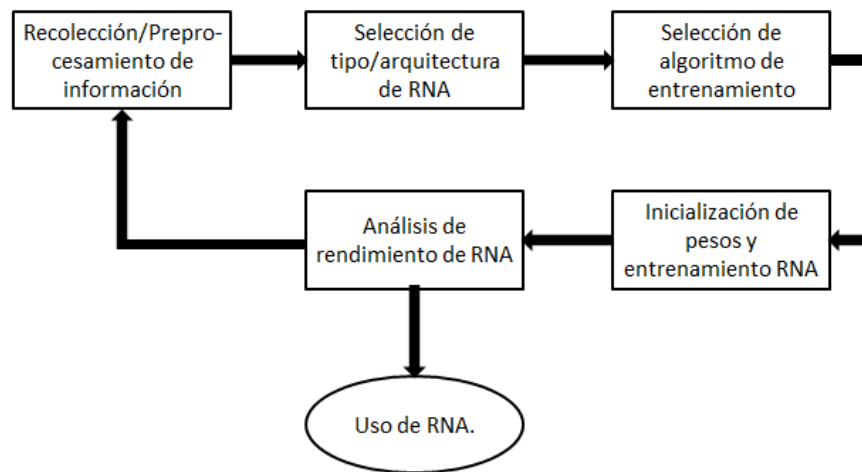


Fig. 13: Diagrama de flujo del proceso de entrenamiento y funcionamiento de las RNA.

Adaptado de: *Neural Network Design.* (Demuth et al., 2014).

Además, este autor distingue entre 4 tipos de problemas que se pueden solucionar con RNA: problemas de ajuste, reconocimiento de patrones, clasificación y predicción. Los problemas de ajuste, también llamados de aproximación o regresión, corresponden a un modelo matemático para calcular un valor dependiendo a unas variables de entrada. Los problemas de reconocimiento de patrones estudian cómo una red neuronal determina las variables de entradas en varios tipos de categoría. Los problemas de clasificación, o

*clustering*, buscan una solución a cómo agrupar un conjunto de datos según la similaridad en sus características. Por último, los problemas de predicción se encargan de realizar una predicción de un valor en una serie de tiempo.

Las consideraciones especiales que se tomen en cada una de las partes que componen el sistema y los métodos matemáticos empleados para resolver las interacciones entre las neuronas artificiales son las que permiten calificar y clasificar dicho RNA. Ozyildirim & Avcı (2013) categorizan distintos tipos de redes neuronales, los más desarrollados en los últimos años, entre ellos están (siglas en inglés):

- Perceptrones multicapa (MLP, *multilayer perceptron*).
- Funciones de base radial (RBF, *radial basis function*).
- Redes neuronales probabilísticas (PNN, *probabilistic neural network*).
- Mapas de organización propia (SOM, *self-organizing map*).
- Redes neuronales celulares (CNN, *celular neural network*).
- Redes neuronales corrientes (RNN, *recurrent neural network*).
- Redes neuronales de regresión generalizada (GRNN, *generalized regression neural network*).

Los modelos de RNA más importantes y más utilizados son GRNN y PNN. Los GRNN (Amrouche & Rouvaen, 2006) están propuestos para funciones de aproximación, siendo de rápido “entrenamiento”, consistencia y regresiones óptimas con gran número de datos. Estos RNA se componen de una capa de entrada de datos, una capa de patrones, una capa de suma y una capa de salida de datos (Fig. 14). El funcionamiento es el siguiente: desde la capa de entrada se envían vectores de datos a la capa de patrones. En esta capa de patrones se encuentran las neuronas artificiales entrenadas, y es dónde se calcula la ponderación de la distancia euclidiana al cuadrado sumando los valores obtenidos y aplicándolos en la función de activación. Las neuronas en la capa de suma, se adicionan luego de haber realizado el producto punto de los valores de la capa de salida con sus ponderaciones correspondientes, así se obtiene el valor predicho de la neurona que se utilizará en la capa de entrada para realizar el proceso nuevamente.




Fig. 14: Esquema de modelo de GRNN de redes neuronales.  
Fuente: Generalized classifier neural network (Ozyildirim et. al., 2013).

Por otra parte, los PNN también cuentan con el mismo número y tipos de capas que las GRNN pero con un funcionamiento relativamente diferente. En esta clase de RNA (Specht 1990), la capa de entrada envía los valores iniciales a la capa de patrones, patrones que se componen de vectores de valores iniciales y vectores de ponderación que se multiplican en un producto punto a la que se le aplica la función de activación (Fig. 15). Los resultados son adicionados en la capa de suma y a partir de ahí se determinan los datos de salida.




Fig. 15: Esquema de modelo de PNN de redes neuronales.

Fuente: Generalized classifier neural network (Ozyildirim et. al., 2013).

Uno de los aspectos más importantes para un funcionamiento óptimo de las RNA, es el aprendizaje de la red. Según Brío et. al. (2001), “es el proceso por la cual una red neuronal modifica sus pesos en respuesta a una información de entrada”. Las RNA deben ser capaces de verificar el valor de la ponderación que se le asigna a cada función dentro de la red, esto se logra con la verificación de los datos de salida y los datos utilizados específicamente para el “entrenamiento” o acondicionamiento de dicha red. Para conocer el grado de aprendizaje de la RNA, debemos observar los pesos sinápticos: si los valores  $w_{ij}$  se mantienen estables, se considera que la red neuronal está entrenada; si los valores  $w_{ij}$  cambian y se vuelven 0, se considera que toda la red neuronal está destruida. Es claro que se debe determinar un criterio para conocer cómo funciona el cambio de las ponderaciones en las conexiones de las neuronas cuando la red procese nueva información.

Existen dos fases que resumen todo el desarrollo del procedimiento de aprendizaje:

- **Fase de aprendizaje:** Hay dos métodos de aprendizaje:

- Aprendizaje supervisado: el proceso de entrenamiento es controlado por un agente externo que regula los datos de salida de las neuronas y manipula los pesos sinápticos a conveniencia. Se puede realizar de 3 formas: aprendizaje por corrección de error (ajuste a partir de las diferencias entre los valores de salida deseados y los valores de salida obtenidos), aprendizaje por refuerzo (ajuste a partir de aceptar o rechazar los valores de salida que se van presentando durante el entrenamiento) y aprendizaje estocástico (ajuste aleatorio en la ponderación hasta encontrar el valor de salida deseado).
- Aprendizaje no supervisado: el proceso de entrenamiento no es controlado por un agente externo y es autosuficiente para la modificación de los pesos sinápticos. Se puede realizar de 2 formas: aprendizaje hebbiano (ajuste dependiendo si dos neuronas consecutivas están en el mismo estado, activas o inactivas) y, aprendizaje competitivo y comparativo (ajuste a partir de revisar si un patrón de datos de entrada pertenece o no a una clase reconocida).
- **Fase de recuerdo:** Luego de haber superado la fase de aprendizaje, es decir, que los pesos sinápticos de las funciones de las RNA queden fijos, la red neuronal está lista para el procesamiento de datos. En las redes neuronales con una sola dirección, las neuronas responden directamente unos datos de salida a partir de un patrón de entrada, sin retroalimentación del sistema y sin problemas de estabilidad del mismo. Por otra parte, las RNA que tienen retroalimentación son sistemas dinámicos no lineales que requieren de ciertas condiciones para que la respuesta termine convergiendo a un valor determinado. Para comprobar la estabilidad de la red neuronal, se aplican metodologías que introducen funciones de Lyapunov, las cuales pueden predecir el comportamiento general de la RNA, siendo una función de energía del sistema que disminuya cada vez que se utilice, comprobando así la estabilidad de la red.

La mejor forma de cuantificar errores en el proceso de aprendizaje de la RNA, es el error cuadrático medio (*MSE*, *mean square error* en inglés). Este estimador estadístico funciona para conocer el error existente entre un valor real  $t_i$  y un valor predicho  $o_i$ . Se puede definir matemáticamente como el promedio de la diferencia cuadrada del valor real y el valor predicho (Ec. 38), o como una función de error o costo que depende de la diferencia

cuadrada entre el valor real y el valor predicho (Ec. 39). Para las redes neuronales artificiales es muy común utilizar la definición descrita en la Ec. 40.

$$MSE = \frac{1}{n} \sum (t_i - o_i)^2 \quad \text{Ec. 38}$$

$$MSE = E[(t_i - o_i)^2] \quad \text{Ec. 39}$$

$$MSE = \sum (t_i - o_i)^T (t_i - o_i) \quad \text{Ec. 40}$$

Hay diversas funciones con las cuales trabaja el error cuadrático medio  $MSE$  para la implementación de los procedimientos de propagación inversa *backpropagation*. Demuth et al. (2014), plantea dos de estas funciones, que son el método de Leverberg-Marquadt y la regularización Bayesiana, y ambas se consideran como funciones de entrenamiento de las RNA. El método de Leverberg-Marquadt (LM) es una variación del método de Newton para minimizar funciones que son suma de los errores de funciones no lineales, tal y como el error cuadrático medio  $MSE$ . Este método considera que el método de Newton donde el índice de rendimiento es una suma de cuadrados, cuya función  $F(x)$  es la expresada en la Ec. 40 denominada  $v_i$ . El gradiente de cualquier elemento  $j$  estaría determinado por la Ec. 41.

$$[\nabla F(x)]_j = \frac{\partial F(x)}{\partial x_j} = 2 \sum_{i=1}^N v_i(x) \frac{\partial v_i(x)}{\partial x_j} \quad \text{Ec. 41}$$

Matricialmente, la Ec. 41 puede escribir como la Ec. 42, donde la matriz Jacobiana está descrita por la Ec. 43.

$$\nabla F(x) = 2J^T(x)v(x) \quad \text{Ec. 42}$$

$$J(x) = \begin{matrix} \frac{\partial v_1(x)}{\partial x_1} & \frac{\partial v_1(x)}{\partial x_2} & \dots & \frac{\partial v_1(x)}{\partial x_n} \\ \frac{\partial v_2(x)}{\partial x_1} & \frac{\partial v_2(x)}{\partial x_2} & \dots & \frac{\partial v_2(x)}{\partial x_n} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial v_N(x)}{\partial x_1} & \frac{\partial v_N(x)}{\partial x_2} & \dots & \frac{\partial v_N(x)}{\partial x_n} \end{matrix} \quad \text{Ec. 43}$$

Después, se necesita calcular la matriz Hessiana (Ec. 44) del elemento  $k, j$ , sea peso sináptico o sesgo, y cuya expresión matricial está dada por la Ec. 45. Esta expresión está conformada por el término  $S(x)$  que se define en la Ec. 46.

$$[\nabla^2 F(x)]_{k,j} = \frac{\partial^2 F(x)}{\partial x_k \partial x_j} = 2 \sum_{i=1}^N \frac{\partial v_i(x)}{\partial x_k} \frac{\partial v_i(x)}{\partial x_j} + v_i(x) \frac{\partial^2 v_i(x)}{\partial x_k \partial x_j} \quad \text{Ec. 44}$$

$$\nabla^2 F(x) = 2J^T(x)J(x) + 2S(x) \quad \text{Ec. 45}$$

$$S(x) = \sum_{i=1}^N v_i(x) \nabla^2 v_i(x) \quad \text{Ec. 46}$$

Debido a que el error que se quiere obtener sea el más pequeño posible, se asume que  $S(x)$  es aproximadamente 0. Así, el método de Levenberg-Marquadt se determina con la expresión matemática de la Ec. 47.

$$x_{k+1} = x_k - [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k)v(x_k) \quad \text{Ec. 47}$$

donde  $I$  es la matriz de valores propios de la matriz Hessiana de la función  $F(x)$  y  $\mu_k$  es un factor que controla el ritmo de la convergencia del procedimiento. Si el resultado de la iteración es una disminución del valor de  $F(x)$ , el factor  $\mu_k$  se divide entre un factor  $\phi$  ( $\phi > 1$ ); en caso contrario, si el valor de  $F(x)$  aumenta, el factor  $\mu_k$  se multiplica por el factor  $\phi$ .

Por otra parte, la regularización Bayesiana (RB) se fundamenta en la teoría de probabilidades condicionales de Bayes y asume que los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$  son variables aleatorias. Se escogen los pesos sinápticos y los sesgos de tal forma que maximicen la función de probabilidad condicional de Bayes (Ec. 48).

$$P(x|D, \alpha, \beta, M) = \frac{P(D|x, \beta, M)P(x|\alpha, M)}{P(D|\alpha, \beta, M)} \quad \text{Ec. 48}$$

Donde  $x$  es el vector que contiene a los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ ,  $D$  son los datos de entrenamiento,  $\alpha$  y  $\beta$  son parámetros asociados a las funciones de densidad  $P(D|x, \beta, M)$  y  $P(x|\alpha, M)$ , y  $M$  es la arquitectura del modelo de la red neuronal artificial, como por ejemplo, el número de capas, las neuronas en cada capa, las funciones de activación, etc. A esta



fórmula matemática se le conoce como la función de densidad posterior (Ec. 48), y se compone de 3 términos probabilísticos.

$$P(D | x, \beta, M) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad \text{Ec. 49}$$

El primer término llamado función de probabilidad (Ec. 49), que describe qué tan probable es que un conjunto de datos suceda debido a un conjunto de pesos sinápticos y sesgos específicos. A su vez, este término se compone de los factores descritos en Ec. 50 y Ec. 51.

$$\beta = \frac{1}{2\sigma_\varepsilon^2} \quad \text{Ec. 50}$$

$$Z_D(\beta) = (2\pi\sigma_\varepsilon^2)^{N/2} \quad \text{Ec. 51}$$

Donde  $\sigma_\varepsilon^2$  es la varianza de cada elemento del conjunto de datos,  $N$  es el número de variables de los datos  $Q$  por el número de ejemplos del conjunto de datos  $S^M$  y  $E_D$  es el error cuadrado medio definido según la Ec. 40 para los datos de entrenamiento.

El segundo término de la Ec. 48, se denomina densidad previa (Ec. 52), y es toda aquella información que se tiene sobre los pesos sinápticos y los sesgos de la RNA antes de recolectar los datos. La densidad previa está determinada por Ec. 53 y Ec. 54.

$$P(x | \alpha, M) = \frac{1}{Z_W(\alpha)} \exp(-\alpha E_W) \quad \text{Ec. 52}$$

$$\alpha = \frac{1}{2\sigma_W^2} \quad \text{Ec. 53}$$

$$Z_W(\alpha) = (2\pi\sigma_W^2)^{n/2} \quad \text{Ec. 54}$$

Donde  $\sigma_W^2$  es la varianza de cada peso sináptico y cada sesgo,  $n$  es el número de pesos sinápticos y sesgos de la red neuronal y  $E_W$  es el error cuadrado medio definido según la Ec. 40 para los pesos sinápticos y sesgos.

Como último término de la Ec. 48, está la Ec. 55, que se nombra como la función de evidencia y que es una expresión normalizadora que no depende de  $x$ , y no es necesaria para encontrar el máximo de la función de densidad posterior (Ec. 48). Además, la función de evidencia está compuesta por los parámetros de Ec. 56 y Ec. 57.

$$P(D|\alpha, \beta, M) = \frac{Z_F(\alpha, \beta)}{Z_D(\beta)Z_W(\alpha)} \quad \text{Ec. 55}$$

$$Z_F(\alpha, \beta) \approx F(x^{MP}) + \frac{1}{2}(x - x^{MP})^T H^{MP} (x - x^{MP}) \quad \text{Ec. 56}$$

$$H^{MP} = \beta \nabla^2 E_D + \alpha \nabla^2 E_W \quad \text{Ec. 57}$$

Se estima  $Z_F(\alpha, \beta)$  como una expansión de la serie de Taylor en donde  $x^{MP}$  representa el valor más probable del peso sináptico o del sesgo en esa iteración y  $H^{MP}$  como la matriz Hessiana de la función  $F(x)$ .

Los parámetros  $\alpha$  y  $\beta$  que se expusieron en la sección asociada a las funciones probabilísticas de la función de regularización bayesiana son diferentes a los parámetros  $\alpha$  y  $\beta$  que se mostrarán a continuación en el método del descenso del gradiente. Desde este punto en adelante, cuando se hable de los parámetros  $\alpha$  y  $\beta$  se trabajará con el significado denotado en el método del descenso del gradiente.

El método del descenso del gradiente es el método más utilizado en el entrenamiento y aprendizaje de las redes neuronales artificiales para obtener la actualización de los parámetros de las neuronas, es decir, las correcciones de los pesos sinápticos y los sesgos (Aggarwal, 2018). Este método consiste en calcular la derivada de la función de costo de la RNA multiplicándola por factores de tasa de decaimiento del aprendizaje  $\alpha$ , parámetro del momentum  $\beta$ , vectores de velocidad de corrección  $V$ , y vectores de pesos sinápticos  $W$ . La aplicación del método del descenso del gradiente permite encontrar de manera rápida el valor óptimo para los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$  (Fig. 16).




Fig. 16: Desempeño del método del descenso del gradiente.  
Fuente: Neural networks and deep learning. (Aggarwal, 2018),

La tasa de decaimiento del aprendizaje  $\alpha_t$  se calcula por decaimiento exponencial (Ec. 58) o por decaimiento inverso (Ec. 59), las cuales dependen de los siguientes parámetros: tasa decaimiento inicial  $\alpha_0$ , el número de épocas del entrenamiento  $t$ , y un factor de control  $k$ .

$$\alpha = \alpha_0 \exp(-k \cdot t) \quad \text{Ec. 58}$$

$$\alpha = \frac{\alpha_0}{1 + k \cdot t} \quad \text{Ec. 59}$$

Esta actualización de los valores de pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ , sintetizados en la matriz  $W$ , se realiza por medio de la expresión matemática mostrada en la Ec. 60, en dónde  $V$  es el vector de velocidad de cambio del aprendizaje.

$$W = W + V \quad \text{Ec. 60}$$

El cálculo y el valor del vector de velocidad  $V$  cambian según la técnica de aprendizaje que se esté utilizando. Existen diversas técnicas de aprendizaje, las más importantes son: técnica sencilla (Ec. 61), técnica de momentum suavizado (Ec. 62) y técnica de momentum de Nesterov (Ec. 63), en donde  $L$  representa la función de costo de la RNA.

$$V = -\alpha \frac{\partial L}{\partial W} \quad \text{Ec. 61}$$

$$V = \beta V - \alpha \frac{\partial L}{\partial W} \quad \text{Ec. 62}$$

$$V = \beta V - \alpha \frac{\partial L(W - \beta V)}{\partial W} \quad \text{Ec. 63}$$

Para Mazurowski (2008), los algoritmos más utilizados para el entrenamiento de las RNA son: el método de propagación inversa desarrollado por Chauvin y Rumelhart (1995), que es una variación del método del descenso del gradiente para encontrar para mínimo de una función de error, usando el procedimiento del error medio cuadrado; y, el método de optimización de “enjambre” de partículas (Eberhart & Kennedy, 1995) que consiste realizar iteraciones variando la posición de los vectores de las posibles soluciones del sistema hasta determinar la respuesta óptima para la función objetivo.

Si se desea utilizar el método de la propagación inversa (*backpropagation*) para ajustar los pesos sinápticos de la RNA durante la etapa de aprendizaje, se deben tener claros 3 conceptos de este método (Sathyanarayana, 2014). El primer concepto es el enfoque de la corrección del error, el cual consiste en seleccionar una de las capas que conforman la red neuronal, aislarla con la capa siguiente y ajustar los pesos sinápticos para corregir el error existente,  $e$ . Esto puede lograrse mediante la aplicación de la suma cuadrada de los errores (Ec. 64), donde  $o_i$  es el valor de entrada de salida de la neurona y  $t_i$  es el valor objetivo de la neurona.

$$e = (o_1 - t_1)^2 + (o_2 - t_2)^2 + (o_3 - t_3)^2 + (o_4 - t_4)^2 \quad \text{Ec. 64}$$

Un ejemplo de una red neuronal artificial compuesta por 4 capas de neuronas es útil para mostrar el funcionamiento del *backpropagation* (Fig. 17). Se escoge la tercera capa para hacer la corrección del error con respecto a la cuarta capa. Se implementa una capa adicional para manejar los valores de los errores calculados  $c_i$  y se expresan como una función (Ec. 65).

$$e = E(c_1, c_2, c_3, c_4, c_5, c_6) \quad \text{Ec. 65}$$




Fig. 17: RNA de 4 capas.

Fuente: *A gentle introduction to backpropagation* (Sathyanarayana, 2014).

El segundo concepto que hay que considerar es la sensibilidad (Ec. 66), se denota  $\delta_{ci}$  y corresponde a las derivadas parciales del vector del error  $E$  con respecto a cada uno de los componentes de ese vector. Por lo tanto, la sensibilidad sigue siendo un vector (Ec. 67), no un número escalar.

$$\delta_i = \frac{\partial E}{\partial c_i} \quad \text{Ec. 66}$$

$$\delta = (\delta_1, \delta_2, \delta_3, \delta_4, \delta_5, \delta_6) \quad \text{Ec. 67}$$

Los valores de entrada a la última capa de la red neuronal que se utilizó para la propagación inversa, son los valores de entrada  $p_i$  para la corrección del error de toda la red. Cualquiera RNA en etapa de entrenamiento sufrirá modificaciones debido a los errores existentes por los datos procesados. Así, se espera una pequeña variación en el error calculado  $\Delta c_i$  que afectado por la sensibilidad  $\delta_{ci}$  permite conocer la sensibilidad  $\delta p_1$  y la variación de estos parámetros de entrada  $\Delta p_I$  de la red (Ec. 68).

$$\delta p_1 = \frac{\partial e}{\partial p_1} \quad \text{Ec. 68}$$

Este proceso matemático es el que le da el nombre al método de corrección del error conocido como *backpropagation*, debido a que la sensibilidad calculada para las capas posteriores se utiliza para ajustar los errores y los pesos sinápticos de las capas anteriores (Fig. 18 y Fig. 19).

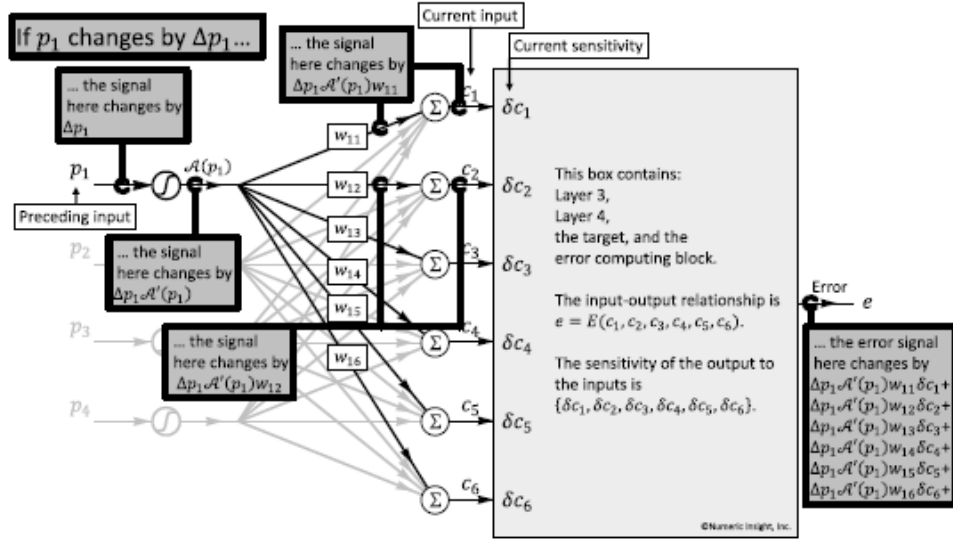


Fig. 18: Cuadro de flujo del procedimiento backpropagation, corrección de  $p_1$  debido a  $\Delta p_1$ .

Fuente: A gentle introduction to backpropagation (Sathyanarayana, 2014).

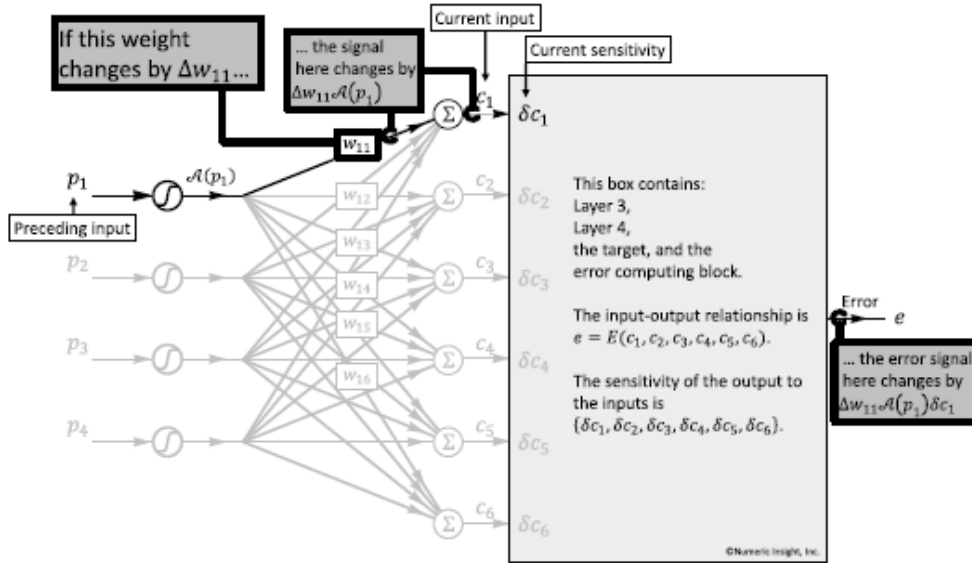


Fig. 19: Cuadro de flujo del procedimiento backpropagation, corrección de  $\Delta w_1$

Fuente: A gentle introduction to backpropagation (Sathyanarayana, 2014).

El tercer y último concepto importante que se debe tener en cuenta es el peso sináptico de las neuronas  $w_{ij}$ . Conociendo lo especificado en Fig. 18 y Fig. 19, se puede determinar un factor  $A(p_1)\delta c_j$  (Ec. 69) que permite entender cómo varía el error en función del cambio de

los pesos sinápticos, que se calcula como la derivada parcial del primer parámetro ( $e$ ) mencionado con respecto al segundo ( $w_{ii}$ ).

$$A(p_i)\delta c_j = \frac{\partial e}{\partial w_{ij}} \quad \text{Ec. 69}$$

Con este factor  $A(p_i)\delta c_j$ , es posible optimizar los pesos sinápticos, mediante iteraciones de la RNA, y minimizar el error, mediante el método del máximo descenso. Para comenzar el funcionamiento de la red, se coloca un valor “semilla” pequeño y se escoge aleatoriamente un conjunto de datos usados en el entrenamiento para que se realice todo el recorrido por las neuronas y las capas de neuronas.

Existen algunas técnicas que mejoran el rendimiento del entrenamiento y la comprobación de una red neuronal artificial. La validación cruzada o *cross-validation*, en inglés, es un método muy efectivo para optimizar la complejidad de la RNA y disminuir el error en datos de prueba desconocidos para la red, por el cual se fraccionan todos los datos aleatoriamente en tres grupos: datos de entrenamiento, datos de validación y datos de prueba (Ertel, 2017). Luego se realiza el entrenamiento de la red neuronal con la información de entrenamiento y con la información de validación, cuyos resultados de error se promedian y se utilizan para calcular el error de la red con los datos de prueba. Este proceso se realiza iterativamente hasta que se encuentre el mínimo error en los resultados de la red. Para bases de datos de pequeña magnitud (100 a 10 000 datos) se utiliza una proporción de 60/20/20 o 70/15/15 en la distribución de datos de entrenamiento, validación y prueba, respectivamente; para bases de datos de gran magnitud (big data, más de 1 000 000 de datos) se utilizan proporciones de 98/1/1 o 99/0.5/0.5.

Otra técnica que beneficia a los múltiples procedimientos matemáticos que se realizan durante el funcionamiento de una red neuronal artificial es la normalización de la información de la base de datos. Esta técnica resulta importante debido a que, generalmente, los diferentes parámetros involucrados en la RNA, ya sean variables de entrada o variables de salida, tienen diferentes órdenes de magnitud, y esta diferencia puede causar que ciertas variables condicionen fuertemente el rendimiento de la red (Aggarwal, 2018). Existen muchos métodos de normalización, algunos de estos están descritos en Ec. 70, Ec. 71, Ec. 72, Ec. 73 y Ec. 74.

$$p^n = 2(p - p^{\min}) ./ (p^{\max} - p^{\min}) - 1 \quad \text{Ec. 70}$$

$$p^n = (p - p^{\text{mean}}) ./ p^{\text{std}} \quad \text{Ec. 71}$$

$$x_{ij}^n = \frac{x_{ij}}{\sigma_j} \quad \text{Ec. 72}$$

$$x_{ij}^n = \frac{x_{ij} - x_{j\min}}{x_{j\max} - x_{j\min}} \quad \text{Ec. 73}$$

$$x_{ij}^n = \frac{x_{ij}}{\|x_j\|} \quad \text{Ec. 74}$$

Demuth et al., (2014) plantean Ec. 70 y Ec. 71, en donde  $p$  es valor a normalizar,  $p^n$  es el valor normalizado,  $p^{\min}$  es el valor mínimo del parámetro que está siendo normalizado,  $p^{\max}$  es el valor máximo del parámetro que está siendo normalizado,  $p^{\text{mean}}$  es la media del parámetro y  $p^{\text{std}}$  es la desviación estándar del parámetro. Ec. 72, Ec. 73 y Ec. 74 son presentadas por Aggarwal (2018), teniendo que  $x_{ij}$  es el valor  $i$  del parámetro  $j$  a normalizar,  $x_{ij}^n$  es el valor normalizado,  $x_{j\min}$  es el valor mínimo del parámetro  $j$ ,  $x_{j\max}$  es el valor máximo del parámetro  $j$ ,  $\sigma_j$  es la desviación estándar del parámetro  $j$  y  $\|x_j\|$  es la norma del vector de datos del parámetro  $j$ .

## 7.5. Sistemas de control


El control y la protección de las estructuras ha sido objetivo de investigación de la ingeniería civil desde la década de los 80. Se ha estudiado la forma de regular los diversos parámetros que intervienen en el análisis y el diseño de las estructuras: materiales de construcción, sistema estructural, las dimensiones, las secciones y la ubicación de los elementos estructurales, tipos de cargas aplicadas, entre otros.

Symans & Constantinou (1999) definen tres (3) grandes clases de sistemas de control:

- **Sistemas de control pasivos:** es un sistema que no requiere una fuente de poder externa para su funcionamiento y utiliza el movimiento propio de la estructura



para desarrollar las fuerzas de control (Fig. 20). Estas fuerzas de control son una función de la respuesta de la estructura dependiendo la localización del sistema de control.



*Fig. 20: Esquema de funcionamiento de los sistemas de control pasivos.*

*Adaptado: Semi-active control systems for seismic protection of structures: a state-of-the-art review. (Symans et al., 1999).*

La importancia de los sistemas de control pasivo radica en que estos mecanismos absorben gran cantidad de la energía sísmica que ingresa a la estructura, reduciendo la demanda del sistema estructural de resistencia sísmica. Singh & Moreschi (2002) y Qu & Li (2012), se dedicaron a investigar cuáles son las mejores configuraciones de ubicación para estos dispositivos y determinaron que es recomendable distribuirlos en cada piso o pisos intercalados para reducir los efectos de las fuerzas sísmicas.

Symans et al. (1999) mencionan diversos mecanismos y dispositivos que funcionan como sistemas de control pasivos: fluencia dúctil del acero, acción visco-elástica de materiales similares al caucho, cizallamiento de fluidos viscosos, fricción por deslizamiento y aislamiento sísmico de la base.

Li & Huo (2010) explican con mayor detalle los sistemas de control pasivos que más se utilizan:

- Aislamiento de la base: Como su nombre lo indica, este método consiste en utilizar elementos y procedimientos que impidan que las fuerzas sísmicas tengan efectos sobre las estructuras. También se pueden aislar determinados pisos de la estructura para alcanzar el mismo objetivo. Algunos ejemplos de la ubicación del aislamiento sísmico en las estructuras se presentan en la Fig. 21.

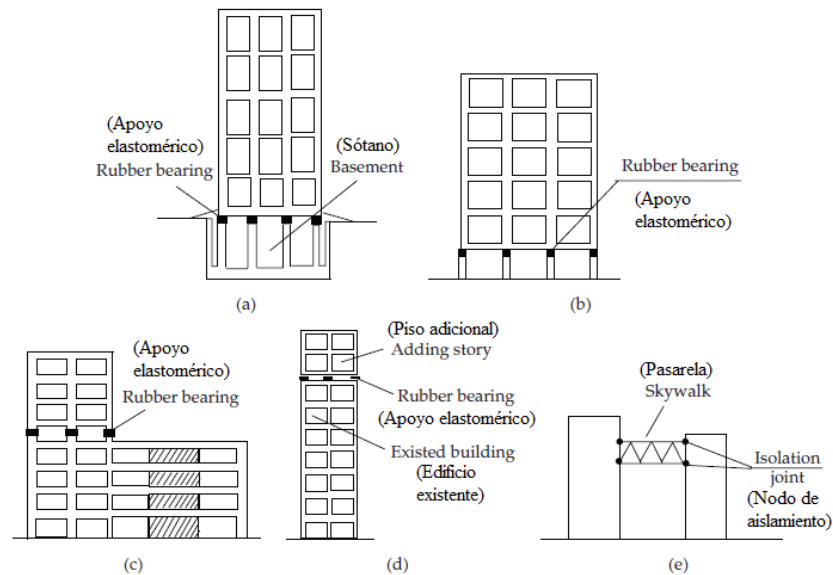


Fig. 21: Ejemplos de aislamiento sísmico.

Fuente: *Advances in structural control in civil engineering in China*. (Li et al., 2010).

Generalmente, el aislamiento sísmico se logra con la colocación de un material que sirva para absorber energía, como por ejemplo capas de arena, capas de mortero de grafito, capas de caucho y rodillos de caucho.

Dentro de los beneficios estructurales que hay al utilizar este tipo de sistemas de control pasivo, se encuentran la disminución (entre 12.5 %-50.0 %) de la respuesta sísmica de la estructura, un ahorro económico (3.0 %-15.0 %) de la estructura final, variedad en formas de aplicación en estructuras existentes y nuevas, y gran duración del sistema (de 75 a 100 años, mayor que la vida útil de la estructura).

– Disipación de energía: se utilizan dispositivos que actúen como amortiguadores que disipen gran cantidad de la energía vibratoria que recibe la estructura, ya sea por cargas sísmicas, de viento o cualquier otro tipo de cargas. Estos dispositivos deben cumplir con funcionamiento histerético, es decir, que sean capaces de mantener sus propiedades físicas y mecánicas ante ciclos de carga y descarga, garantizando el adecuado comportamiento del instrumento a lo largo de su vida útil. Existen diversos tipos de amortiguadores: amortiguadores de fricción (se usan como frenos para disipar

la energía cinética, pueden ser de cualquier material con una configuración mecánica simple, y poseen un comportamiento histerético estable, Fig. 22), amortiguadores viscoelásticos (son importantes porque disipan energía sin importar la deformación que puedan experimentar, Fig. 23), amortiguadores de líquido viscoso (la capacidad de disipación de energía depende de la composición del líquido), amortiguadores de plomo (tienen un comportamiento elasto-plástico ideal, con un ciclo de histéresis rectangular (Garcia, 1998), ante sismos fuertes son de baja efectividad porque disipan poca energía por su alta deformación) y amortiguadores metálicos (se aprovecha la no linealidad, después de la fluencia, del material para seguir deformándose y disipar energía).



*Fig. 22: Amortiguador de fricción.*

*Fuente: Advances in structural control in civil engineering in China. (Li et al., 2010).*



*Fig. 23: Amortiguador viscoelástico.*

*Fuente: Advances in structural control in civil engineering in China. (Li et al., 2010).*

– Amortiguador de masa sincronizado: en inglés, TMD (*tuned mass damper*), consiste en una masa adicional a la estructura que está conectada con resortes y amortiguadores a la estructura principal, pero que posee una curva de histéresis que depende de la frecuencia, lo que aumenta el amortiguamiento de la estructura (Fig. 24). El periodo del TMD debe ser el mismo de la estructura para que al momento de la ocurrencia del sismo, este actúe en contra del movimiento de la edificación y reduzca la respuesta sísmica.



*Fig. 24: Amortiguador de masa sincronizado.*

*Fuente: Advances in structural control in civil engineering in China. (Li et al., 2010).*

– Amortiguador de líquido sincronizado: en inglés, TLD (*tuned liquid damper*), funcionan bajo el mismo principio de los TMD, es decir, aumentan el amortiguamiento de la estructura, moviéndose en sentido contrario, para disminuir los efectos de los movimientos sísmicos (Fig. 25). Existe un amortiguador de columna líquida, TLCD (*tuned liquid column damper*), dónde se disipa la energía por el paso de un líquido a través de un orificio sin pérdida de cargas. Este tipo de amortiguadores se utiliza para estructuras con grandes periodos y funciona mejor controlando los dos modos fundamentales de la estructura, uno por cada dirección principal del plano horizontal.




Fig. 25: Esquema de funcionamiento de un amortiguador de líquido sincronizado.  
Fuente: *The technology advances in modern civil engineering. (UKEssays, 2015).*

- **Sistemas de control activos:** es un sistema que reduce la respuesta estructural de una edificación mediante una resistencia que resulta de una fuente de poder externa (Fig. 26). Este tipo de control utiliza dispositivos que aplican fuerzas en tiempo real, debido a que están conectados a la estructura por evaluadores: controladores y sensores. Los evaluadores proporcionan un mecanismo de equilibrio ante cargas que pueden perjudicar a la estructura (Rai et al., 2009).




Fig. 26: Esquema de funcionamiento de los sistemas de control activos.  
Fuente: *Semi-active control systems for seismic protection of structures: a state-of-the-art review. (Symans & Constantinou, 1999)*

Fisco & Adeli (2011), clasificaron 4 grandes tipos de sistemas del control activo:

- Amortiguador de masa sincronizado activo: funciona con el mismo dispositivo TMD que en el sistema de control pasivo. Para que esto sea un sistema de control activo, existe un actuador que está ubicado entre el TMD y la estructura, que permite la aplicación de una fuerza externa cuando sea

requerida. La ventaja de este dispositivo con respecto al sistema pasivo, es que permite la variación de la frecuencia fundamental del dispositivo TMD (Fig. 27).




Fig. 27: Esquema de funcionamiento de TMD activo.

Fuente: *Sistemas de control de respuesta sísmica en edificaciones.* (Oviedo & Duque, 2006).

– Actuadores distribuidos: consisten en diversos algoritmos trabajando simultáneamente, resolviendo sistemas de ecuaciones, que optimizan el control y la respuesta estructural ante cualquier tipo de carga dinámica (cargas de impacto, cargas de viento, cargas de sismo). Los actuadores existentes deben suministrar la fuerza necesaria para contrarrestar el movimiento de la estructura cuando sea afectada por alguna carga externa (Fig. 28).




Fig. 28: Esquema de funcionamiento de actuadores distribuidos en un sistema de combustión.

Fuente: *Nonlinear feedback control of self-sustained thermoacoustic oscillations.* (Rubio-Hervas et al., 2015).

- Sistema de tendones activos: Los tendones de este sistema son elementos presforzados que se ubican en los entre pisos de la edificación o al final de los cables en puentes. Los actuadores activos se encargan de ajustar la tensión necesaria en los tendones y así generar la fuerza de control que se debe aplicar a la estructura.
- Sistema de edificios acoplados activos: consiste en construir edificaciones que estén conectadas entre sí para mejorar la respuesta sísmica de ambas estructuras. Además, se pueden adicionar unos actuadores en las edificaciones para aumentar el nivel de control. La efectividad de este sistema de control depende de la localización de la interacción y los actuadores en las estructuras.
- **Sistemas de control semi-activos:** este tipo de sistemas de control son la combinación de los sistemas activos y pasivos, resolviendo los principales problemas de dichos mecanismos: gran cantidad de energía externa requerida y gran espacio requerido para el dispositivo, respectivamente (Fig. 29). En general, los sistemas de control semi-activos se componen de un dispositivo pasivo optimizado y sincronizado con la estructura para que el sistema de control necesite mucha menos energía para su ejecución (Rai et. al., 2009).

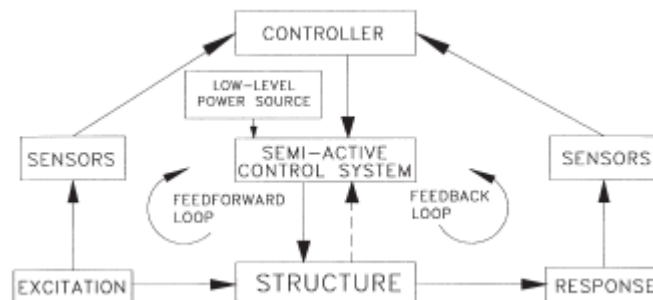



Fig. 29: Esquema de funcionamiento de los sistemas de control semi-activos.

Fuente: *Semi-active control systems for seismic protection of structures: a state-of-the-art review.*  
(Symans & Constantinou, 1999).

Existen diversos mecanismos de sistemas de control semi-activos. Para Symans & Constantinou (1999), los más importantes son los siguientes:

– Dispositivos de control de rigidez: como su nombre lo indica, son elementos que permiten modificar la rigidez de la estructura, modificando las características de vibración naturales, para evitar la resonancia de la edificación durante la ocurrencia de un sismo. Estos dispositivos están ubicados en los elementos de arriostramiento de la estructura y se activan o desactivan para incluir o no, la rigidez de dicho arriostramiento (Fig. 30).



*Fig. 30: Ejemplo de dispositivo de control de rigidez.*

*Fuente: Semi-active control systems for seismic protection of structures: a state-of-the-art review. (Symans & Constantinou, 1999).*

El principio de estos dispositivos se asemeja al de un pistón de un motor de gasolina, debido a que se compone de un cilindro hidráulico con una válvula de control solenoide que está conectada a dos cámaras de cilindros.

– Amortiguadores electroreológicos: estos amortiguadores consisten en un cilindro hidráulico lleno de un fluido (generalmente aceite) con micro partículas dieléctricas suspendidas, que al momento de interactuar con algún campo eléctrico, estas se polarizan, se alinean y producen una resistencia al movimiento (Fig. 31).



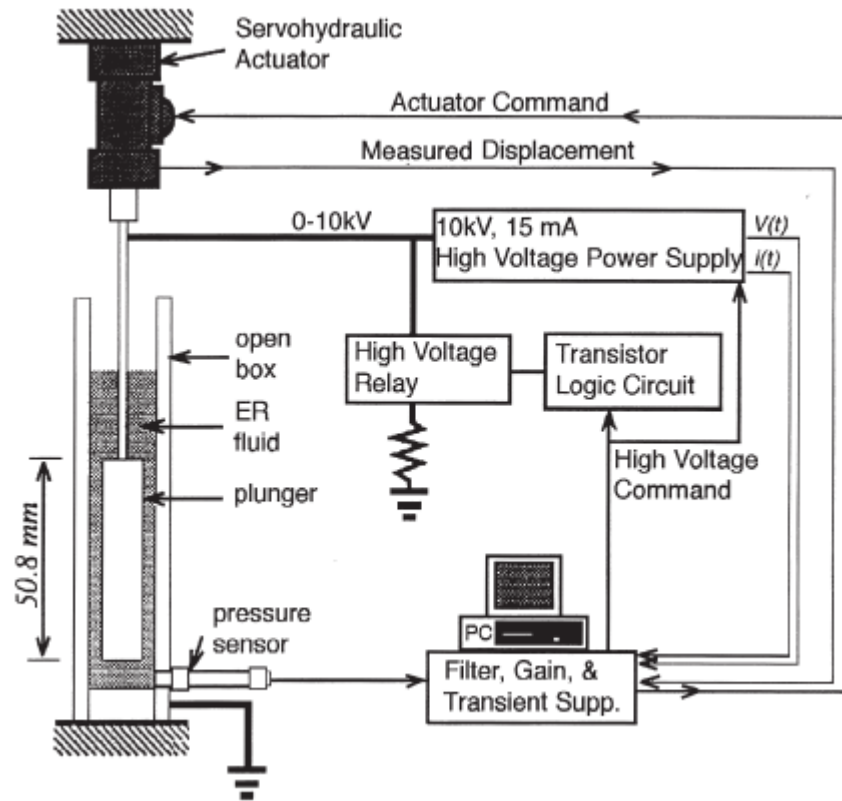


Fig. 31: Amortiguador electrorreológico.

Fuente: Design method for high-force electrorheological dampers. (Gavin, 1998).

Según el campo eléctrico aplicado, la fuerza generada por el amortiguador electrorreológico se puede controlar, permitiendo que este material pase de ser un fluido viscoso a ser un sólido en fluencia, en cuestión de milisegundos (Gavin, 1998).

– Amortiguadores magnetorreológicos: son amortiguadores muy similares a los electrorreológicos, con la diferencia que actúan con campos magnéticos y no con campos eléctricos (Fig. 32).




Fig. 32: Amortiguador magnetoreológico.

Fuente: *Modeling and control of magnetorheological dampers for seismic response reduction.* (Dyke et al., 1996).


La viscosidad del fluido magnetoreológico se regula a partir de la intensidad del campo magnético utilizado, o del voltaje que se le aplique al fluido. Para Mori, Nilkhamhang & Sano (2007), la fuerza de amortiguamiento que se tiene que obtener debe ser suficiente para poder disminuir las vibraciones y desplazamientos de los elementos.

- Dispositivos de control de fricción: generalmente son amortiguadores de fricción, que dependen del desplazamiento de la estructura y no de la velocidad ni de la frecuencia de vibración. Los amortiguadores de fricción se activan sí y solo sí la fuerza ejercida a la edificación excede la fricción máxima permitida y genera un desplazamiento (Lu, 2004).

- Amortiguadores de fluido viscoso: Similar los dispositivos de control de rigidez, estos amortiguadores funcionan a partir de un cilindro hidráulico con un pistón que está lleno del fluido viscoso, generalmente aceite, y que separa ambos lados de dicho cilindro. Al momento de la aplicación de la fuerza

externa, el fluido pasa a través de pequeños orificios a una velocidad que es regulada con una válvula de control que está en el sistema. De esta velocidad, depende la fuerza de amortiguamiento que genera este tipo de dispositivos.

– Amortiguadores de masa sincronizada y de líquido sincronizado: es el mismo dispositivo que se utiliza en los sistemas de control pasivo y activo (TMD). Lin, Lu, Lin, & Yang (2010) desarrollaron un sistema de control semi-activo con este tipo de amortiguador para disminuir problemas de vibración estructural (Fig. 33).



*Fig. 33: Amortiguador de masa sincronizada TMD.*

*Fuente: Vibration control of seismic structures using semi-active friction multiple tuned mass dampers. (Lin et al., 2010).*

A medida que se ha avanzado en el desarrollo de nuevos sistemas y dispositivos de control, y mejoramiento de las técnicas y elementos ya existentes, la comparación teórica y experimental entre sistemas de control se hace más interesante. Por ejemplo, Mitu et al., (2015) estudiaron la respuesta sísmica de una misma estructura que interactuaba con un sistema de control pasivo con un amortiguador de fricción y con un sistema semi-activo con un amortiguador magnetoreológico. Se llega a la conclusión, en este caso, que el amortiguamiento magnetoreológico es más eficiente que el de fricción.

Todos los sistemas de control son útiles para disminuir los efectos de cargas sísmicas, cargas de viento y cargas cíclicas que se aplican sobre una estructura. Por lo tanto, es importante conocer conceptos y técnicas para la correcta escogencia del sistema de control.

Ou & Li (2009) dan recomendaciones de funciones y algoritmos para diferentes tipos de sistemas de control activos, pasivos y semi-activos.

Además de los sistemas de control mencionados anteriormente, Fisco & Adeli (2011) categorizan un tipo adicional de sistemas de control, a los cuales denominan “híbridos” y que resultan de la combinación de sistemas, metodologías y dispositivos activos, pasivos y semi-activos. Entre los sistemas de control híbridos que se explican, los más relevantes son:

- Amortiguadores de masa híbridos: conocidos como HMD (por sus siglas en inglés, *hybrid mass damper*) se componen de un TMD activo y cualquier tipo de amortiguadores pasivos. Para un funcionamiento eficiente, este sistema debe tener un controlador interno que regule la activación del TMD activo y del amortiguador pasivo, asegurando que ambos dispositivos puedan generar la fuerza necesaria para disminuir los efectos de la carga sísmica.
- Sistema de control semi-activo de aislamiento de base: la metodología pasiva de aislamiento de base no es tan eficiente para edificios muy altos con un periodo fundamental muy largo. Por lo tanto, este sistema de control se ha combinado con otros, como amortiguadores de fluido viscoso (Fig. 23), amortiguadores electrorreológicos (Fig. 31) o, amortiguadores magnetorreológicos (Fig. 32) para obtener una mejor respuesta sísmica de la estructura.
- Actuadores y amortiguadores pasivos: conociendo la desventaja de los sistemas de control activos de necesitar permanentemente una fuente de energía externa, este tipo de sistema de control surgió por la necesidad de seguir controlando la edificación durante un sismo, debido a que durante el evento sísmico puede existir un corte de fluido eléctrico. Así, cuando salgan de funcionamiento los actuadores de una estructura, los amortiguadores pasivos utilizados en el sistema híbrido seguirán controlando la edificación. A este modo de trabajo se le llama “falla segura”.
- Amortiguador semi-activo de columna líquida sincronizada y amortiguadores pasivos: con la implementación de esta técnica híbrida, se toman en consideración las ventajas de los sistemas de control pasivos y semi-activos, incrementando la durabilidad, rendimiento, operatividad, efectividad y robustez ante las excitaciones sísmicas y de viento.

## 8. METODOLOGÍA

El desarrollo metodológico de esta tesis de maestría se realizará en 4 fases que se describen a continuación: la primera fase consiste en realizar un análisis de dominio de frecuencias de señales sísmicas, la segunda fase trata sobre análisis matricial por el método de la rigidez y sobre análisis modal, la tercera fase desarrolla una red neuronal artificial y la cuarta fase hace una revisión de criterios de decisión para implementar en los sistemas de control. Estas 4 fases en conjunto, permiten conseguir el Objetivo general de esta investigación. En la Fig. 34, se muestra un diagrama de flujo que describe la interacción entre las fases anteriormente mencionadas.

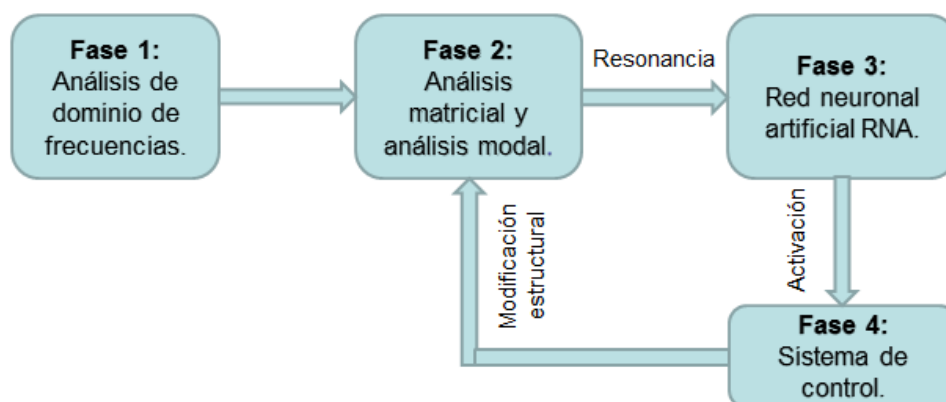


Fig. 34: Diagrama de flujo de la metodología para esta tesis. Fuente: Elaboración propia.

Toda esta tesis se desarrolló con ayuda del software *Matlab R2019a* y se estructuró como un programa principal (Anexo 1) que presenta y permite la interacción de 3 algoritmos específicos que realizan los procedimientos descritos en los subcapítulos 8.1, 8.2 y 8.3, respectivamente.

### 8.1. Análisis del dominio de frecuencias

Lo primero que se debe realizar en esta fase de esta tesis, es conseguir registros sísmicos correspondientes a diferentes sismos. Estos registros sísmicos se pueden consultar en varias bases de datos especializadas, en esta investigación se consultaron las bases de datos del CESDM (en inglés *Center for Earthquake Strong Motion Data*, EE.UU.), USGS (en

inglés, *National Strong Motion Project*, EE.UU.), y SGC (*Servicio Geológico Colombiano*, Colombia). Se tomaron señales sísmicas correspondientes a los últimos 80 años, de cualquier magnitud, en cualquier lugar del mundo, debido a que se tienen registros desde 1940 y se busca variedad en las características de estos sismos.

Debido a la diversidad del formato en la presentación de los datos, se ha optado por realizar un filtro manual de los registros y luego utilizar un algoritmo de organización de la información para la estandarización de formatos y que puedan ser interpretados fácilmente por un software. Esta organización de los datos se realiza a partir de los siguientes parámetros: unidad de aceleración, tiempo del registro e intervalo de muestreo de datos. Se plantea realizar una matriz con los valores del tiempo, obtenidos al dividir el tiempo del registro entre el intervalo de muestreo, y la aceleración de cada registro que compone el sismo.

Después de realizar esta organización de la información, el algoritmo (Anexo 2) ejecuta un filtro de la señal sísmica analizada, mediante el uso de las funciones de *Matlab*, *butter* y *filter*. Este filtro consiste en remover el “ruido”, o datos atípicos, a los registros sísmicos obtenidos, con la finalidad de tener mejores resultados al momento de procesar la señal.

Cada señal sísmica que se registra mediante instrumentación específica, contiene una gran cantidad de información perteneciente al evento sísmico ocurrido. Esta información es muy importante para caracterizar el comportamiento del sismo, pues permiten conocer las magnitudes de la aceleración, el tiempo de duración, epicentro, hipocentro, etc. A partir de estos datos, se determinan otras variables que amplían la categorización del sismo en estudio, dentro de las variables se encuentran las magnitudes de las velocidades y los desplazamientos durante el sismo y las frecuencias experimentadas.

Para conocer las velocidades y los desplazamientos del sismo, se utiliza la función de *Matlab*, *cumsum* con los datos de aceleración obtenidos del registro sísmico. Esta función realiza una aproximación de la integral acumulativa de un arreglo de datos mediante el método trapezoidal. Así, teniendo los datos de aceleración y aplicando la función *cumsum*, se obtienen la información de las velocidades, y aplicando nuevamente la función *cumsum*, se calculan los datos de desplazamiento del sismo. Toda esta información se grafica para ver de mejor manera el comportamiento de los datos.

Con la información de la aceleración registrada durante el sismo, se utilizan los conceptos de las transformadas de Fourier y los análisis en dominio del tiempo y de la frecuencia (subcapítulo 7.1). De esta forma se calcula el espectro de amplitud de frecuencias del registro sísmico, en el cual se determina la frecuencia dominante del sismo la cual es parte fundamental de la presente investigación.

## **8.2. Análisis matricial por el método de la rigidez y análisis modal**

Como el nombre de esta fase lo indica, esta parte de la tesis se encarga de realizar el análisis matricial por el método de la rigidez y el análisis modal para pórticos 2D, con el objetivo de conocer las propiedades y el comportamiento de respuesta dinámico de una estructura con diversas configuraciones de arriostramiento. Estos análisis se realizan con la teoría expuesta en el subcapítulo 7.3.

Es necesario realizar diversas observaciones y condiciones que se tienen en cuenta para la implementación de esta fase de la presente investigación:

- Estos análisis se realizan a estructuras de cortante idealizados, de acuerdo a Chopra (2001).
- Sólo se trabajará con pórticos 2D (arriostrados y no arriostrados), con número de pisos entre 1 y 10, que contarán únicamente con dos columnas (un solo vano) de igual sección transversal.
- Las riostras a utilizar en los pórticos, en los diferentes pisos de la estructura, serán en forma de “V” invertida, para utilizar un sistema de control semi-activo adecuado.
- Las estructuras que son analizadas en esta tesis, deben cumplir previamente con los criterios y requerimientos de diseño pertinentes.
- Los elementos estructurales considerados corresponden a perfiles metálicos de material ASTM A992 Grado 50 para vigas y columnas (HEA e IPE), y ASTM A500 Grado C para las riostras (PTE).
- Las cargas muertas a implementar corresponden a estructuras de uso residencial o de oficinas, que estén dentro del grupo de uso tipo I.

Teniendo claras las consideraciones anteriormente mencionadas, se procede a introducir toda la información de la estructura al algoritmo (Anexo 3) que realiza el análisis matricial

y el análisis modal. Los parámetros necesarios para el cálculo de estos análisis son los siguientes:

- Número de pisos de la estructura.
- Altura de pisos.
- Longitud de vano entre columnas.
- Área de columnas.
- Inercia de columnas.
- Área de vigas.
- Área de riostras.
- Ubicación de las riostras de acuerdo al piso de activación.
- Cargas muertas sobreimpuestas.

Se consideraron 4 formas distintas para obtener estos parámetros de la estructura:

- Nueva estructura: Se digita toda la información de la estructura vía teclado y pantalla.
- Estructura previamente analizada: Se toma la información de una estructura a la cual ya se le haya realizado el análisis matricial y el análisis modal.
- Estructura existente en base de datos: Se toma la información de una estructura determinada que está en la base de datos utilizada para el proceso con la red neuronal artificial.
- Estructura propuesta por la RNA: Se toma la información de la estructura que resulta del procesamiento de la red neuronal artificial.

Con las variables de la estructura completamente definidas, se ejecutan el análisis matricial mediante el método de la rigidez y el análisis modal (subcapítulo 7.3). Para este algoritmo, se han implementado 3 opciones para el tratamiento de la información calculada:

- Ver resultados del análisis estructural: Como resultado del análisis matricial, se muestran los periodos y las frecuencias de cada uno de los grados de libertad definidos según el número de pisos. Del análisis modal, se obtienen los modos de vibración de la estructura. Además, si se ha ejecutado previamente el algoritmo de análisis del dominio de frecuencias de un sismo (subcapítulo 8.1), se calculan y se grafican la masa modal,



los desplazamientos totales de la estructura, la fuerza horizontal equivalente, el cortante basal y el momento basal que experimenta el pórtico debido al sismo.

- Verificar resonancia entre la estructura y el sismo: Se muestra la frecuencia principal de la estructura y la frecuencia dominante del sismo, para compararlos y determinar la resonancia, según los criterios de factores de respuesta dinámica (subcapítulo 7.2). En caso de que se presente resonancia, el usuario puede escoger entre ejecutar o no el algoritmo de las RNA (subcapítulo 8.3)
- Ingresar la información de la estructura en la base de datos: se toma la información de la estructura y del análisis matricial para realizar una nueva entrada de la base de datos existente.

Con la última opción presentada anteriormente, se genera la base de datos de estructuras con la que funcionará el algoritmo de las redes neuronales artificiales (subcapítulo 8.3). Para lograr este objetivo, se realizó un diseño de experimentos. Montgomery (2004) determina que en los experimentos intervienen el estudio de dos o más factores y clasifica el diseño factorial como aquel diseño en el cuál se analizan todas las combinaciones posibles hechas con los factores que están presentes en el experimento. Estas combinaciones se producen a través de la interacción de los distintos niveles de los factores. Así, se denomina que el diseño de experimentos está cruzado.

Este autor también propone distintos tipos de experimentos para conocer cuál es la incidencia de los factores y sus respectivos niveles en cada muestra del experimento. Los diseños factoriales más utilizados son  $2^2$ ,  $2^3$ ,  $2^k$ ,  $3^2$ ,  $3^3$  y  $3^k$ . Los experimentos mencionados se caracterizan por tener el número de factores mostrados en el exponente (2, 3 y  $k$ ) con un número de niveles expresados en el denominados (2 y 3).

Es necesario realizar distintos filtros para las combinaciones obtenidas del diseño de experimento debido a que existen combinaciones que son estructuralmente imposibles, porque los elementos estructurales no cumplen con los criterios de diseño, o porque existen combinaciones repetidas como se explica a continuación. Para el primer filtro, se realiza un estudio de sensibilidad mediante modelos estructurales en el software *SAP2000* que determina hasta dónde el nivel de un factor se puede combinar con los niveles de los demás factores. El segundo filtro consiste en eliminar aquellas combinaciones redundantes que

resulten por el diseño de experimentos, debido a que algunas variaciones en los niveles de los factores producen los mismos resultados y esto puede sesgar la base de datos.

### **8.3. Red neuronal artificial RNA**

La red neuronal artificial es la parte más importante de la tesis debido a que a través de su funcionamiento, se toman las decisiones con respecto a los cambios de la configuración estructural para evitar la resonancia del pórtico con el sismo en estudio. Después de documentar la teoría sobre el tema (subcapítulo 7.4), se procede a realizar el armado y montaje de la RNA.

El primer paso para comenzar con el desarrollo de las redes neuronales artificiales es determinar cuáles son las variables de entrada y las variables de salida. Resulta esencial definir de manera adecuada estos parámetros porque de su grado de interacción depende el funcionamiento y el rendimiento de la RNA.

Dentro de esta arquitectura se encuentran varios parámetros como el número de capas de la red y el número de neuronas en cada capa (dependen de la complejidad del problema), las funciones de propagación, de activación y de salida de las neuronas (dependen del tipo de problema a resolver) y las funciones de error y algoritmos de entrenamiento (depende de las variables de salida).

Algunas de las variables descritas anteriormente se pueden establecer antes de realizar algún procesamiento de la RNA, como por ejemplo, las variables de entrada, las variables de salida, las funciones de propagación, de activación y de salida de las neuronas, y las funciones de error. Con el análisis detallado de la literatura, se pueden definir estas variables. Por otra parte, el número de capas de la red, las neuronas de cada capa y el algoritmo de entrenamiento, se deben ajustar mediante el método de ensayo y error, en el cual se prueban distintos valores para calcular la configuración que ofrezca los mejores resultados en términos de error y ajuste de los datos.

Para obtener mejores resultados de la RNA, se realizaron los métodos de validación cruzada, en donde se dividen los datos de entrenamiento, de validación y de prueba en una proporción de 70/15/15. A continuación se ejecutó una normalización de variables, en donde se normaliza toda la información de la base de datos con respecto a la variable a la

que pertenecen para evitar diferencias considerables en los órdenes de magnitud de los parámetros en estudio. Finalmente, se hizo una codificación de la información, para simplificar la cantidad de datos que se manejan en la red neuronal artificial.

Luego de haber definido con precisión toda la arquitectura de la RNA, se sigue con el entrenamiento de la red neuronal, esto se realiza con el propósito de calcular los valores óptimos de los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ , y que tengan el menor error y el mejor ajuste de la información de la base de datos.

En este algoritmo (Anexo 4) se han colocado 3 opciones para el tratamiento de los resultados obtenidos para la RNA:

- Visualización de la RNA: Se muestra cómo está formada la red neuronal artificial, con todos los parámetros involucrados en los procesos matemáticos de la RNA.
- Reentrenamiento de la RNA: Se realiza un nuevo cálculo de las redes neuronales para determinar otros valores para los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ .
- Predicción de la RNA: Se realiza la predicción de la información de la RNA, a partir de los datos utilizados en el algoritmo de análisis matricial y análisis modal (subcapítulo 8.2). Si la frecuencia del sismo y la frecuencia de la estructura se encuentran en resonancia, la RNA multiplica la frecuencia principal de la estructura por un factor de 1.65. Este factor se define para amplificar dicha frecuencia y evitar el intervalo indeseado de resonancia (se busca un valor 20 % mayor al límite superior del rango de intervalos de resonancia definidos por el respectivo factor de resonancia, entre 0.6 y 1.4, según Fig. 2 y Fig. 4). Este resultado es utilizado como variable de entrada para predecir una configuración estructural que se aproxime a esa frecuencia y se aleje del intervalo indeseado de resonancia. Posteriormente, se puede regresar al algoritmo de análisis matricial y análisis modal para estudiar la efectividad de la solución predicha.

#### **8.4. Sistemas de control**

Como última fase de esta tesis, se realiza una revisión detallada de criterios de decisión para escoger de un sistema de control para implementar en esta investigación. Este análisis se debe realizar sobre los diferentes tipos de control existentes, es decir, activos, pasivos y

semi-activos. También se deben estudiar los mecanismos y los dispositivos que pertenecen a cada sistema de control.

Conocer las ventajas y las desventajas de cada tipo de instrumento permite formar un criterio sólido para escoger el sistema de control sísmico más adecuado para esta investigación. Cabe resaltar que en esta tesis no se desarrollará ningún sistema de control; solamente se propondrá la mejor solución para el problema estudiado con las consideraciones tomadas en cuenta durante todo el documento.

## 9. RESULTADOS Y DISCUSIÓN

Como está descrito en el capítulo 8 (metodología), esta tesis consta de 4 fases. Con la interacción de las 4 fases mencionadas, se sigue el diagrama de flujo mostrado en la Fig. 34 y se presentan los resultados obtenidos en cada una de las fases de esta tesis.

### 9.1. Análisis del dominio de frecuencias

La primera fase corresponde al análisis de dominio de frecuencias para un evento sísmico registrado. Dentro de esta investigación, se buscaron registros de acelerogramas en las bases de datos especializadas: CESMD, NSMP y SGC. En esta investigación, se tomaron señales sísmicas correspondientes a los últimos 80 años, de cualquier magnitud, en cualquier lugar del mundo. Algunos sismos relevantes del siglo pasado como los de El Centro (1940) y Kobe (1995), y algunos sismos de este siglo como los de Los Santos-Colombia (2015) y Manabí-Ecuador (2016).

Se seleccionaron 9 registros para el estudio, los sismos son los siguientes:

- **Berkeley, California, EE.UU.** Fecha: 4 de septiembre de 2003. Duración del registro: 44 segundos. Magnitud (MI): 3.9. (Anexos Anexo 12 y Anexo 27).
- **Cerro Pietro, México.** Fecha: 8 de febrero de 2008. Duración del registro: 79.00 segundos. Magnitud (MI): 5.4. (Anexos Anexo 13 y Anexo 28).
- **Greenville, California, EE.UU.** Fecha: 16 de marzo de 2015. Duración del registro: 88.44 segundos. Magnitud (Mw): 3.8. (Anexos Anexo 14 y Anexo 29).
- **Manabí, Ecuador.** Fecha: 16 de abril de 2016. Duración del registro: 995.06 segundos. Magnitud (Mw): 7.8. (Anexos Anexo 15 y Anexo 30).
- **Los Santos, Santander, Colombia.** Fecha: 10 de marzo de 2015. Duración del registro: 112.00 segundos. Magnitud (Mw): 6.4. (Anexos Anexo 16 y Anexo 31).
- **Tijuana, México.** Fecha: 31 de marzo de 2017. Duración del registro: 176.96 segundos. Magnitud (MI): 3.5. (Anexos Anexo 17 y Anexo 32).
- **El Centro, California, EE.UU.** Fecha: 19 de mayo de 1940. Duración del registro: 53.74 segundos. Magnitud (Mw): 6.9. (Anexo 18).
- **Kobe, Japón.** Fecha: 17 de enero de 1995. Duración del registro: 150.02 segundos. Magnitud (Mw): 6.9. (Anexo 19).

- **Northridge. California, EE.UU.** Fecha: 17 de enero de 1994. Duración del registro: 60.02 segundos. Magnitud (MI): 6.7. (Anexo 20).

Al estudiar el comportamiento de todas las señales sísmicas consultadas, se observó que las máximas aceleraciones se presentan en intervalos de tiempo de entre 30.0 s a 40.0 s en los diferentes registros, por lo tanto, en esta investigación se mostrará el periodo de tiempo con mayor relevancia en el contenido sísmico de cada uno de los registros presentados. El periodo y el intervalo de tiempo analizado de todos los registros sísmicos es el siguiente:

- **Berkeley, California, EE.UU.:** 30.0 segundos (5.0 s a 35.0 s).
- **Cerro Pietro, México:** 40.0 segundos (7.5 s a 47.5 s).
- **Greenville, California, EE.UU.:** 30.0 segundos (25.0 s a 55.0 s).
- **Manabí, Ecuador:** 40.0 segundos (25.0 s a 65.0 s).
- **Los Santos, Santander, Colombia:** 40.0 segundos (20.0 s a 60.0 s).
- **Tijuana. México:** 40.0 segundos (20.0 s a 60.0 s).
- **El Centro. California, EE.UU.:** 40.0 segundos (0.0 s a 40.0 s).
- **Kobe. Japón:** 40.0 segundos (0.0 s a 40.0 s).
- **Northridge. California, EE.UU.:** 30.0 segundos (0.0 s a 30.0 s).

Para este documento, se van a tomar como ejemplo los sismos ocurridos en Tijuana, México, y el ocurrido en Los Santos, Santander, Colombia, a los cuales se le va a realizar el análisis del dominio de frecuencias.

Inicialmente, se deben obtener los registros numéricos documentados de los acelerogramas de los eventos sísmicos (Fig. 35 y Fig. 36). En estos casos en particular, se consultaron las páginas web del CESMD y del SGC, respectivamente. Se tomaron los datos de la estación de Dulzura, en Tijuana, México, ubicada a 22.2 km del epicentro del sismo de Tijuana y de la estación Vereda Acapulco en Girón, Santander, Colombia, ubicada a 20.9 km del epicentro del sismo de Los Santos. Debido a la complejidad del formato de los datos de los acelerogramas, se decidió hacer una organización mediante un algoritmo para facilitar el manejo de la información (Fig. 37 y Fig. 38).

CIDZAV2: Bloc de notas									
<p>           Archivo Edición Formato Ver Ayuda            Corrected accelerogram 37845672.CI.DZA---.HN Chan 1: 90 Deg from            Uncorrected Accelerogram Data Processed: 04/01/17, CGS cidza--k            Rcrd of Fri Mar 31, 2017 23:40:24.0 PDT (Avoll v1.4, 7/16 CSMIP)            (Origin: To be determined)            37845672.CI.DZA---.HN Start time: 4/01/17, 06:40:24.0 UTC (GPS)            Station Id. DZA 32.607N, 116.775W ObsMMS s/n 5768 (3 Chns of 6 at Sta)            Dulzura SCSN Data: Acceleration            Chan 1: 90 Deg            Rcrd of Fri Mar 31, 2017 23:40:24.0 PDT Fri Mar 31, 2017 23:40:24.0 PDT            Hypocenter: To be determined. ML: To be determined.            Instr Period = .0050 sec, Damping = .707, Sensitivity = 4.98 v/g (Nominal)            Record Length =176.960 sec.            Uncor Max = .007 g, at 24.880 sec.            RMS accel of (uncor) record = . Chn. metadata effective date:            Accelerogram bandpass filtered with 3 dB pts at .30 and 23.00 cyc/sec            8848 points of instrument- and baseline-corrected accel, veloc and displ data            At equally-spaced intervals of .020 sec.            Peak acceleration = -5.928 cm/sec/sec at 28.120 sec.            Peak velocity = .109 cm/sec at 27.680 sec.            Peak displacement = .002 cm at 27.520 sec.            Initial velocity = .000 cm/sec; Initial displacement = .000 cm            Rcrd of Fri Mar 31, 2017 23:40:24.0 PDT Fri Mar 31, 2017 23:40:24.0 PDT            37845672.CI.DZA---.HN Dulzura Chan 1: 90 Deg            1 100 1 6 6 100 -999 3 1 0 15 5768 0 0 41 0            6 40 24 3 91 4 1 2017 10 3 9017696 39 7 74 -999            17696 -999 100 6 -999 -999 -999 -999 -999 -999 -999 -999 -999 -999            -999 -999 -999 -999 8848 2 -999 0 -999 20 -999 -999 2 1 -999 8848            3 8848 4 -999 -999 3 5 0 0 -999 0 -999 -999 6 -999 2            2 2 4 -999 -999 -999 -999 -999 -999 -999 1 -999 -999 -999 111            1 1 -999 -999            .0050000 .7071000 176.96000 .0003318 1.0000000 4981.6760 .0072006 24.880000            200.00000 2.3841880 .4785915 -999.00000 10.00000 -999.00000 4.0000000 -999.00000            20.000000 5.6533180 .000 -999.00000 -999.00000 -999.00000 -999.00000 .0015469            -.0013711 -.0029180 2.0000000 15.00000 32.606570 -116.77480 .0020987 .0018860         </p>									

Fig. 35: Formato de datos de acelerogramas obtenidos del sismo de Tijuana, México.

Fuente: CESMD.

2015-03-20150310205544_CGIR2.anc: Bloc de notas									
<p>           Archivo Edición Formato Ver Ayuda            SERVICIO GEOLOGICO COLOMBIANO- RED NACIONAL DE ACELEROGRAFIOS DE COLOMBIA SISMO DE LOS SANTOS (SANTANDER) 2015/03/10 20:55:44 MM=6.4 LATITUD DEL EVENTO(GRADOS): 6.83 LONGI         </p>									
2.09760640	11.38401040	-18.76926400	2.07805600	11.39068640	-18.75305200	2.07948720	11.38782480	-18.76068000	
.76401920	2.09140800	11.38639440	-18.78213920	2.09379200	11.36922800	-18.79978160	2.09045440	11.38019600	
39164000	-18.76497280	2.09188480	11.36875120	-18.76211200	2.09569920	11.37495040	-18.76735680	2.08711600	
2.09951440	11.36636720	-18.77641680	2.08568560	11.37924160	-18.77164880	2.08568560	11.39783840	-18.77069440	
8.75543600	2.09712960	11.39783840	-18.77927760	2.09045440	11.39545440	-18.76544960	2.10952720	11.40117680	
.39974560	-18.76211200	2.08187120	11.39688480	-18.76974080	2.09617600	11.38639440	-18.77212560	2.10094480	
2.09665280	11.38019600	-18.76735680	2.08377840	11.40451440	-18.76640320	2.07328800	11.42644880	-18.77021760	
18.76544960	2.07805600	11.36779760	-18.77307920	2.06613520	11.39783840	-18.77450960	2.08234800	11.39926880	
1.38544080	-18.77641680	2.09426880	11.37352000	-18.77689360	2.08616240	11.38401040	-18.78356960	2.07710240	
2.08950080	11.38973200	-18.76068000	2.09093120	11.38877840	-18.76211200	2.08806960	11.38067280	-18.78213920	
-18.77069440	2.08330160	11.38639440	-18.77403280	2.08711600	11.40642160	-18.77450960	2.09140800	11.39450080	
11.38734800	-18.76974080	2.06375120	11.40880560	-18.76497280	2.08187120	11.39783840	-18.77498640	2.09045440	
2.08759280	11.36541360	-18.77832400	2.08997760	11.38019600	-18.75877360	2.10237520	11.38114960	-18.76735680	
-18.77307920	2.09283840	11.36732080	-18.77069440	2.08377840	11.39259360	-18.77594000	2.08902320	11.38925520	
11.40451440	-18.77450960	2.06851920	11.38639440	-18.77355600	2.08187120	11.39068640	-18.77594000	2.09045440	
2.09474560	11.38258000	-18.77212560	2.10380560	11.38544080	-18.76115760	2.10952720	11.39545440	-18.77641680	
-18.77641680	2.08377840	11.38687120	-18.76592640	2.09188480	11.38925520	-18.76735680	2.10523600	11.38210320	
11.38830160	-18.77021760	2.07710240	11.39926880	-18.77832400	2.08473200	11.39164000	-18.77784720	2.07662560	
2.08997760	11.37113600	-18.76449600	2.11668000	11.39545440	-18.77546320	2.11715680	11.39211680	-18.76735680	
-18.77403280	2.11143520	11.41452800	-18.76926400	2.07901040	11.40451440	-18.76211200	2.05278400	11.40594480	
11.37828800	-18.75734320	2.09569920	11.37113600	-18.77260240	2.09712960	11.38591760	-18.78643040	2.09999120	
2.09045440	11.36827440	-18.77117120	2.08902320	11.37876480	-18.77498640	2.08425520	11.39450080	-18.76592640	
-18.77021760	2.08377840	11.38210320	-18.77307920	2.08806960	11.38734800	-18.76783360	2.09331520	11.38353360	
11.36970560	-18.76735680	2.09188480	11.38734800	-18.77975440	2.10666640	11.39068640	-18.78976800	2.09426880	
2.07805600	11.38353360	-18.78213920	2.06518160	11.38544080	-18.77212560	2.08044080	11.38305680	-18.77212560	
-18.76640320	2.09474560	11.37447360	-18.77594000	2.09045440	11.37971840	-18.77737040	2.09379200	11.38782480	
11.37685760	-18.76163520	2.09283840	11.37638080	-18.76926400	2.10380560	11.36875120	-18.77164880	2.10380560	
2.09760640	11.38734800	-18.77069440	2.10094480	11.37781120	-18.77403280	2.09283840	11.39116320	-18.77784720	
-18.76831040	2.09569920	11.39783840	-18.77450960	2.09808320	11.38353360	-18.76497280	2.08806960	11.37161280	
11.40356800	-18.77307920	2.10328800	11.39688480	-18.77212560	2.10189840	11.39068640	-18.77069440	2.09379200	
2.07614880	11.39688480	-18.75686640	2.10475920	11.39974560	-18.76068080	2.11811040	11.37733440	-18.76544960	
-18.76926400	2.13623040	11.36970560	-18.76974080	2.12097200	11.38401040	-18.77737040	2.07328800	11.39307040	
11.40451440	-18.77737040	2.08425520	11.39783840	-18.77546320	2.09003680	11.40022240	-18.76449600	2.09856000	
2.10094480	11.38019600	-18.77737040	2.09003680	11.40070000	-18.77307920	2.09093120	11.38877840	-18.77307920	
-18.77117120	2.09331520	11.38830160	-18.77212560	2.08425520	11.38401040	-18.77212560	2.07519520	11.36493680	

Fig. 36: Formato de datos de acelerogramas obtenidos del sismo de Los Santos, Santander, Colombia.

Fuente: SGC.

AceleracionSismoTijuana.txt: Bloc de notas							
Archivo	Edición	Formato	Ver	Ayuda			
-0.000123	0.000116	-0.000126	0.000113	-0.000126	0.000114	-0.000130	0.0001053
-0.000142	0.000107	-0.000125	0.000110	-0.000147	0.000089	-0.000137	0.0001131
-0.000116	0.000094	-0.000158	0.000093	-0.000148	0.000110	-0.000117	0.0000769
-0.000158	0.000092	-0.000145	0.000178	-0.000098	0.000053	-0.000180	0.000089
-0.000109	0.000126	-0.000118	0.000012	-0.000277	0.000149	-0.000024	0.0002381
-0.000206	-0.000124	-0.000212	0.000204	-0.000001	0.000179	-0.000268	-0.0001768
-0.000228	0.000313	0.000110	0.000120	-0.000417	-0.000165	0.000032	0.0005018
0.000030	-0.000151	-0.000437	-0.000186	0.000015	0.000575	-0.000215	-0.0003397
-0.000467	0.000366	0.000382	-0.000018	-0.000810	-0.000208	0.000009	0.0005583
0.000304	0.000059	-0.000539	-0.000137	0.000328	0.000780	-0.000044	-0.0007305
-0.000770	0.000341	0.000436	0.000650	-0.000727	-0.000720	-0.000538	0.0005109
-0.000748	-0.000036	-0.000913	-0.000654	0.000014	0.001224	0.000352	-0.0005937
-0.001234	0.000299	0.000662	0.001023	0.000036	-0.001094	-0.000741	0.0007918
0.000429	0.000375	-0.000852	-0.000758	0.000006	0.001019	0.000490	-0.0000526
-0.001381	0.000232	0.000710	0.000998	0.000678	-0.000493	-0.000851	-0.0001176
0.000732	0.000661	-0.000436	-0.000501	-0.000378	0.001119	0.000464	-0.0004163
-0.000290	-0.000132	0.000243	0.000561	-0.000428	-0.000261	-0.000594	0.0004083
0.000339	-0.000465	-0.000077	-0.000175	-0.000237	0.001223	0.000400	-0.0000661
-0.000921	-0.000097	0.000217	0.000106	0.000089	-0.000055	-0.000028	0.0008247
0.000782	-0.000410	-0.000945	0.000473	0.000648	-0.000036	-0.000499	-0.0003997
-0.000395	0.001212	0.000930	-0.000464	-0.001627	-0.000514	0.001087	0.001387
0.001108	-0.001707	-0.002476	0.000949	0.002796	0.001841	-0.001695	-0.0026941
-0.000434	0.002282	0.002351	-0.000750	-0.002592	-0.001612	0.000195	0.0029739
0.000673	-0.000730	-0.002117	-0.001334	0.001849	0.002088	0.000151	-0.0014528
-0.002603	0.000184	0.002122	0.001003	-0.001594	-0.002666	-0.001220	0.0021888
0.002764	-0.000909	-0.004062	-0.000900	0.002888	0.003081	-0.000462	-0.0020303
-0.003136	0.000162	0.003103	0.001611	-0.002068	-0.002692	-0.000726	0.0025197
0.001953	0.000571	-0.001521	-0.002093	-0.000549	0.002306	0.002171	0.0005114
-0.002305	-0.002921	0.000819	0.003912	0.001632	-0.002631	-0.003314	0.0003147
0.002236	0.002154	-0.001381	-0.002528	-0.001987	0.001328	0.002163	0.0004487
-0.001133	-0.001438	0.000538	0.002361	0.000702	0.000711	-0.000130	-0.0014052
-0.000116	0.001319	0.000502	-0.000918	-0.001831	-0.000886	0.000590	0.0013083
0.000926	-0.000340	-0.001376	0.001459	0.000168	0.000376	0.000555	-0.0006499
-0.000192	0.000546	0.000929	0.000702	-0.000894	-0.000454	0.000216	0.0007937
-0.000212	-0.000169	-0.000563	-0.000222	-0.000329	0.000282	-0.000493	0.0002277
0.001278	0.000714	-0.001084	-0.001093	0.000383	0.002255	0.000640	-0.0004438

Fig. 37: Formato de datos de acelerogramas organizados del sismo de Tijuana, México, EE.UU.

Fuente: Elaboración propia.

AceleracionSismoLosSantos.txt: Bloc de notas							
Archivo	Edición	Formato	Ver	Ayuda			
0.000033	0.000032	0.000031	0.000030	0.000029	0.000029	0.000029	0.000030
0.000031	0.000032	0.000031	0.000028	0.000024	0.000019	0.000013	0.000006
0.000001	-0.000003	-0.000006	-0.000009	-0.000013	-0.000018	-0.000023	-0.000026
-0.000024	-0.000016	-0.000004	0.000010	0.000019	0.000024	0.000023	0.000017
0.000009	-0.000003	-0.000019	-0.000041	-0.000067	-0.000091	-0.000101	-0.000090
-0.000057	-0.000009	0.000037	0.000061	0.000049	0.000001	-0.000075	-0.000161
-0.000232	-0.000267	-0.000254	-0.000197	-0.000116	-0.000039	0.000011	0.000025
0.000006	-0.000027	-0.000059	-0.000081	-0.000091	-0.000096	-0.000100	-0.000106
-0.000114	-0.000130	-0.000156	-0.000192	-0.000227	-0.000247	-0.000238	-0.000206
-0.000165	-0.000136	-0.000130	-0.000140	-0.000149	-0.000142	-0.000114	-0.000076
-0.000049	-0.000050	-0.000082	-0.000133	-0.000181	-0.000197	-0.000166	-0.000085
0.000024	0.000118	0.000146	0.000074	-0.000095	-0.000317	-0.000529	-0.000675
-0.000722	-0.000663	-0.000508	-0.000276	0.000002	0.000272	0.000460	0.000492
0.000333	0.000022	-0.000326	-0.000571	-0.000616	-0.000453	-0.000167	0.000112
0.000270	0.000259	0.000114	-0.000078	-0.000216	-0.000232	-0.000118	0.000074
0.000271	0.000406	0.000445	0.000385	0.000246	0.000054	-0.000169	-0.000404
-0.000627	-0.000790	-0.000822	-0.000652	-0.000261	0.000283	0.000830	0.001204
0.001279	0.001050	0.000633	0.000228	0.000021	0.000101	0.000411	0.000774
0.000991	0.000951	0.000672	0.000261	-0.000181	-0.000605	-0.001020	-0.001444
-0.001877	-0.002277	-0.002567	-0.002676	-0.002566	-0.002253	-0.001799	-0.001275
-0.000733	-0.000208	0.000263	0.000644	0.000904	0.001029	0.000999	0.000777
0.000327	-0.000329	-0.001056	-0.001624	-0.001816	-0.001550	-0.000930	-0.000191
0.000412	0.000707	0.000662	0.000367	-0.000038	-0.000461	-0.000898	-0.001389
-0.001933	-0.002433	-0.002746	-0.002772	-0.002511	-0.002051	-0.001505	-0.000982
-0.000583	-0.000394	-0.000469	-0.000784	-0.001233	-0.001667	-0.001982	-0.002156
-0.002227	-0.002221	-0.002108	-0.001810	-0.001278	-0.000574	0.000114	0.000542
0.000516	-0.000029	-0.000993	-0.002140	-0.003170	-0.003821	-0.003945	-0.003535
-0.002708	-0.001649	-0.000569	0.000311	0.000788	0.000742	0.000208	-0.000615
-0.001432	-0.001961	-0.002034	-0.001627	-0.000833	0.000181	0.001186	0.001904
0.002066	0.001506	0.000245	-0.001464	-0.003164	-0.004330	-0.004552	-0.003701
-0.001977	0.000159	0.002144	0.003509	0.004034	0.003796	0.003094	0.002286
0.001623	0.001149	0.000729	0.000176	-0.000588	-0.001438	-0.002087	-0.002254
-0.001825	-0.000903	0.000266	0.001388	0.002218	0.002639	0.002675	0.002436
0.002027	0.001490	0.000808	-0.000031	-0.000950	-0.001762	-0.002229	-0.002162
-0.001488	-0.000297	0.001157	0.002528	0.003474	0.003758	0.003306	0.002251
0.000895	-0.000403	-0.001361	-0.001823	-0.001710	-0.000985	0.000308	0.001948

Fig. 38: Formato de datos de acelerogramas organizados del sismo de Los Santos, Santander, Colombia.

Fuente: Elaboración propia.



El algoritmo de análisis del dominio de la frecuencia comienza con la lectura de los datos de los sismos (Fig. 37 y Fig. 38) y la relación de estos valores con su tiempo de ocurrencia correspondiente. Siguiendo la metodología, se realiza el filtro de las señales sísmicas mediante la implementación de las funciones *butter* y *filter* del software *Matlab*. Después de este filtro, se utiliza la función *cumsum* y se calcula el registro de velocidad de los sismos. Para determinar el registro de desplazamientos de los sismos, se repiten los pasos del filtro de la señal de velocidad y la función *cumsum* para calcular la respectiva integral. De esta forma se pueden graficar los parámetros principales de los acelerogramas: aceleración ( $a$ ) vs. tiempo ( $t$ ) (Fig. 39 y Fig. 42), velocidad ( $v$ ) vs. tiempo ( $t$ ) (Fig. 40 y Fig. 43) y desplazamiento ( $d$ ) vs. tiempo ( $t$ ) (Fig. 41 y Fig. 44), para observar el comportamiento de los sismos durante el tiempo de los sucesos.







Fig. 39: Gráfica del acelerograma del sismo de Tijuana, México. Fuente: Elaboración propia.




*Fig. 40: Gráfica de velocidades del sismo de Tijuana, México. Fuente: Elaboración propia.*




*Fig. 41: Gráfica de desplazamientos del sismo de Tijuana, México. Fuente: Elaboración propia.*



*Fig. 42: Gráfica del acelerograma del sismo de Los Santos, Colombia. Fuente: Elaboración propia.*



*Fig. 43: Gráfica de velocidades del sismo de Los Santos, Colombia. Fuente: Elaboración propia.*



*Fig. 44: Gráfica de desplazamientos del sismo de Los Santos, Colombia. Fuente: Elaboración propia.*

A partir de la teoría de Duhamel para la respuesta dinámica en estructuras ante movimientos sísmicos, las transformadas de Fourier y, los análisis en dominio del tiempo y frecuencia, se determinan aspectos asociados a la respuesta dinámica (desplazamiento, velocidad y aceleración).

Luego, utilizando el concepto matemático de las transformadas de Fourier, el algoritmo procede a hacer un análisis de los sismos en dominio de frecuencias, el cual permite identificar las frecuencias dominantes de los registros, que corresponden a aquellas frecuencias que tienen la mayor amplitud espectral.


Debido a que este análisis en el dominio de frecuencias se está ejecutando en un sistema de control semi-activo, las transformadas de Fourier se deben realizar constantemente en intervalos de tiempo determinados para procesar el registro sísmico en tiempo real. Con esta condición, se propone ejecutar el análisis en el dominio de frecuencias cada 1.0 s y evaluar el cambio de configuración estructural cada 5.0 s (Guzmán et. al., 2017).

Para los ejemplos en estudio, se determina que se realizarán las transformadas de Fourier en los tiempos 2.5 s, 5.0 s, 10.0 s, 15.0 s, 20.0 s, 30.0 s y al final del sismo, para analizar el comportamiento de las frecuencias predominantes a medida que se va registrando la señal

sísmica. En la Tabla 2, la Tabla 3, y desde la Fig. 45 hasta la Fig. 52, se muestran los resultados obtenidos.

*Tabla 2: Frecuencias predominantes en distintos momentos de tiempo del sismo de Tijuana, México. Fuente: Elaboración propia.*

Tiempo (s)	Frec. Predom. (Hz)
2.50	9.180
5.00	9.326
10.00	8.984
15.00	8.984
20.00	8.984
30.00	8.984
176.96	8.984



*Fig. 45: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 2.5 s. Fuente: Elaboración propia.*




Fig. 46: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 5.0 s. Fuente: Elaboración propia.




Fig. 47: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 10.0 s. Fuente: Elaboración propia.




Fig. 48: Gráficas de amplitud espectral en función de las frecuencias del sismo de Tijuana, México a los 15.0 s. Fuente: Elaboración propia.

Tabla 3: Frecuencias predominantes en distintos momentos de tiempo del sismo de Los Santos, Santander, Colombia. Fuente: Elaboración propia.

Tiempo (s)	Frec. Predom. (Hz)
2.50	0.195
5.00	0.977
10.00	0.977
15.00	0.977
20.00	0.977
30.00	0.977
112.00	0.977




Fig. 49: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 2.5 s. Fuente: Elaboración propia.




Fig. 50: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 5.0 s. Fuente: Elaboración propia.






Fig. 51: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 10.0 s. Fuente: Elaboración propia.




Fig. 52: Gráficas de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia a los 15.0 s. Fuente: Elaboración propia.

Finalmente, en la Fig. 53 y la Fig. 54, se detalla el contenido frecuencial de todo el registro sísmico de ambas señales.




Fig. 53: Gráfica de amplitud espectral en función de las frecuencias del sismo de Tijuana, México. Fuente: Elaboración propia.




Fig. 54: Gráfica de amplitud espectral en función de las frecuencias del sismo de Los Santos, Santander, Colombia. Fuente: Elaboración propia.

Los valores de las frecuencias que estén relacionados con la mayor amplitud espectral del registro, serán tomados como las frecuencias dominantes de los sismos y serán los valores a utilizar por el algoritmo del análisis matricial y análisis modal para conocer si existe resonancia con una estructura que se estudiará posteriormente y para que el algoritmo de la red neuronal artificial tome decisiones sobre la configuración estructural de dicho pórtico.

Al analizar los resultados anteriormente mostrados, se observa que las frecuencias predominantes de los sismos se muestran desde el inicio de la señal, alcanzándose a los 10.0 s (Tijuana) y a los 5.0 s (Los Santos) de ocurrencia de cada uno los sismos analizados. Bajo este criterio, se escogerán las frecuencias predominantes definitivas de los sismos que corresponden a 8.984 Hz y 0.977 Hz, para los sismos de Tijuana y Los Santos, respectivamente. Estos datos serán almacenados en una variable especial llamada *frecdom*, para poder ser leídos y utilizados por los algoritmos que siguen.

## **9.2. Análisis matricial por el método de la rigidez y análisis modal**

En la segunda fase de esta tesis, se encuentra un análisis matricial por el método de la rigidez y el análisis modal de pórticos 2D. Estos análisis permiten conocer el análisis estructural y el comportamiento dinámico del pórtico analizado debido a los sismos utilizados en la primera fase de esta tesis, respectivamente. Es necesario resaltar que las estructuras que se analizan en esta investigación y con este algoritmo deben cumplir todas las consideraciones descritas en el subcapítulo 8.2.

Como se había descrito en los capítulos anteriores, los parámetros de la estructura requeridos para realizar los análisis de este algoritmo son: número de pisos, altura de pisos, longitud de vano, área e inercia de columna, área de vigas, área de riostras y ubicación de riostras por pisos. El resultado del análisis matricial es la frecuencia fundamental de la estructura, que es la variable fundamental para determinar si existe resonancia con respecto a la frecuencia dominante del sismo previamente analizado. La información utilizada en este análisis, también se utiliza para formar la base de datos de las estructuras que harán parte de los datos de entrenamiento, validación y prueba de la red neuronal artificial.

Con respecto a la base de datos (Anexo 21), esta se conformó mediante un diseño de experimentos factorial cruzado (Montgomery 2004). En esta tesis, se consideró que el

diseño de experimento apropiado para la base de datos es el  $3^k$ . Tomando todos los parámetros requeridos para el análisis de estructuras se utilizaron tres niveles: un nivel mínimo, un nivel máximo y un nivel intermedio. Con esto, tenemos un diseño del tipo  $3^8$ . A continuación se muestra la Tabla 4 en la cual se encuentra el diseño de experimentos realizado. Hay que resaltar que aunque en la Tabla 4 se encuentren 7 factores, los factores son 8 en realidad, debido a que de la sección de la columna se toman los valores de área y de inercia de la sección.

*Tabla 4: Factores y niveles del diseño de experimentos factorial  $3^8$ . Fuente: Elaboración propia.*

Factor / Nivel	1 (Mínimo)	2 (Intermedio)	3 (Máximo)
Número de pisos	1	5	10
Altura de pisos (m)	3.00	4.00	5.00
Longitud de vano (m)	4.00	5.50	7.00
Sección de columnas	HEA 200	HEA 360	HEA 500
Sección de vigas	IPE 200	IPE 360	IPE 500
Sección de riostras	PTE	PTE	PTE
	100×100×3.0	150×150×4.0	200×200×7.0
Configuración de riostras	Sin riostras	Aleatorio	Todas las riostras

Todas las combinaciones posibles producto del diseño de experimentos factorial  $3^8$  se encuentran en el Anexo 34. Luego de obtener todas estas combinaciones, se realizan distintos filtros sobre estos resultados para obtener combinaciones estructuralmente posibles y que no estén repetidas. Para el primer filtro, se determinó un estudio de sensibilidad mediante modelos estructurales en el software *SAP2000* en dónde se estudiaron variaciones de los parámetros de sección las columnas, vigas y riostras con respecto al número de pisos, la altura de pisos y la longitud del vano, y así determinar el nivel máximo en el que funcionan estos factores. Los resultados de este primer filtro se muestran en la Tabla 5.

*Tabla 5: Estudio de sensibilidad de factores del diseño de experimentos. Fuente: Elaboración propia.*


Factor estudiado / Factor limitante	Nivel máximo		
	Número de pisos	Altura de pisos	Longitud del vano
Sección columna HEA 200	2	3	3
Sección columna HEA 360	3 (con riostras)	3	3
Sección columna HEA 500	3	3	3
Sección viga IPE 200	3	3	2
Sección viga IPE 360	3	3	3
Sección viga IPE 500	3	3	3
Sección riostras PTE 100×100×3.0	3	3	3
Sección riostras PTE 150×150×4.0	3	3	3
Sección riostras PTE 200×200×7.0	3	3	3

El segundo filtro consiste en eliminar aquellas combinaciones en las cuales se pueden presentar resultados iguales. Con esta consideración se estudian las combinaciones que tienen el nivel 1 (sin riostras) del factor “configuración de riostras” y en las que se varíen los niveles del factor “sección de riostras”, debido a que la inexistencia de riostras produce un resultado igual para cualquier sección de riostras estudiado. Además, se realizó un filtro adicional el cual consistía en eliminar las combinaciones que tuvieran en cuenta el nivel 2 (aleatorio) del factor “configuración de riostras” y el nivel 1 (1 piso) de “número de pisos”, puesto que estos resultados están incluidos dentro de los niveles 1 y 3 (sin riostras y todas las riostras) del factor “configuración de riostras”. Después de estos filtros, se obtiene que el total de muestras de este experimento es de 1 104 datos, porque se eliminaron 1 083 combinaciones de las 2 187 que se generan por este diseño de experimentos 3<sup>8</sup>. Toda esta información también se encuentra en el Anexo 34.

En el caso puntual de este documento, en el ejemplo mostrado a continuación se introducen los datos de una nueva estructura, la cual cuenta con las siguientes características:

- Número de pisos de la estructura: 8 pisos.
- Altura de pisos: 3.50 m.
- Longitud de vano entre columnas: 6.50 m.
- Área de columnas:  $0.0159 \text{ m}^2$  (HEA400).
- Inercia de columnas:  $0.0004507 \text{ m}^4$  (HEA400).
- Área de vigas:  $0.00845 \text{ m}^2$  (IPE 400).
- Área de riostras:  $0.001164 \text{ m}^2$  (PTE 100×100×3.0).
- Ubicación de las riostras por pisos: Sin riostras.
- Código de la riostra: 255.

El dibujo esquemático del pórtico en estudio se muestra en la Fig. 55.



*Fig. 55: Estructura 2D en estudio. Fuente: Elaboración propia.*

Luego de realizar el análisis matricial de este pórtico, se obtuvo que la frecuencia fundamental de la estructura es 11.475 Hz. Para determinar la existencia de la resonancia en las estructuras, se realiza la siguiente operación, que es el cociente entre la frecuencia dominante del sismo y la frecuencia fundamental de la estructura. A este cociente se le llama relación de resonancia.

Como se están estudiando dos registros sísmicos al tiempo, primero se presentarán los resultados con respecto al sismo de Tijuana, México y posteriormente se mostrarán los resultados con respecto al sismo de Los Santos, Santander, Colombia. De esta forma, para el primer sismo se obtienen los siguientes resultados.

$$Re s = \frac{f_{domsismo}}{f_{fundestr}} = \frac{8.984}{11.475} = 0.783$$

El criterio escogido en esta investigación para evitar el fenómeno de la resonancia se basa en las gráficas de factores de respuesta dinámica y de transmisibilidad de fuerzas, conceptos expuestos por Chopra (2001) y Clough & Penzien (1975). Según la Fig. 2, se determina que la relación de resonancia debe ser menor que 0.6 o mayor a 1.4 para que no se presente el fenómeno de la resonancia. Otra forma de comprobar la existencia de resonancia es calcular las frecuencias resonantes de desplazamiento (Ec. 10), de velocidad (Ec. 11) y de aceleración (Ec. 12).

$$\omega_{dRes} = \omega_n \sqrt{1 - 2\xi^2} = 11.475 * \sqrt{1 - 2(0.05)^2} = 11.446 \text{ Hz}$$

$$\omega_{vRes} = \omega_n = 11.475 \text{ Hz}$$

$$\omega_{aRes} = \frac{\omega_n}{\sqrt{1 - 2\xi^2}} = \frac{11.475}{\sqrt{1 - 2(0.05)^2}} = 11.504 \text{ Hz}$$

De los resultados anteriores, se puede observar que esta estructura se encuentra en resonancia debido a que la frecuencia dominante del sismo es 79.6 % de la frecuencia natural del pórtico y se encuentra dentro de los límites de la relación de resonancia (Chopra 2001, Fig. 2).

A partir de esto, se calculan la transmisibilidad de fuerzas (Ec. 9), el factor de respuesta dinámica resonante de desplazamiento (Ec. 13), el factor de respuesta dinámica resonante de velocidad (Ec. 14) y el factor de respuesta dinámica resonante de aceleración (Ec. 15) que se produce por el sismo.

$$TR = \left( \frac{1 + [2\xi(\omega / \omega_n)]}{[1 - (\omega / \omega_n)^2]^2 + [2\xi(\omega / \omega_n)]^2} \right)^{1/2}$$

$$= \left( \frac{1 + [2 * 0.05 * (8.984 / 11.475)]}{[1 - (8.984 / 11.475)^2]^2 + [2 * 0.05 * (8.984 / 11.475)]^2} \right)^{1/2} = 2.630$$



$$R_{dRes} = \frac{1}{2\xi\sqrt{1-\xi^2}} = \frac{1}{2*0.05*\sqrt{1-(0.05)^2}} = 10.013$$

$$R_{vRes} = \frac{1}{2\xi} = \frac{1}{2*0.05} = 10.00$$

$$R_{aRes} = \frac{\sqrt{1-\xi^2}}{2\xi} = \frac{\sqrt{1-(0.05)^2}}{2*0.05} = 9.987$$

Se observa que estos factores, tanto de transmisibilidad como de respuesta dinámica resonante de desplazamiento, de velocidad y de aceleración, amplifican 2.63 y 10 veces más los efectos experimentados por la estructura, respectivamente, debido al pórtico y al sismo que se están analizando. Esto concluye que se necesita modificar la configuración estructural del pórtico para evitar las consecuencias negativas de la resonancia existente.

Los resultados obtenidos por la interacción entre el sismo de Los Santos, Santander, Colombia y la estructura anteriormente propuesta, son los siguientes.

$$Re s = \frac{f_{domsismo}}{f_{fundestr}} = \frac{0.977}{11.475} = 0.085$$

La relación de resonancia calculada es 0.085 y se encuentra por fuera del intervalo (de 0.6 a 1.4) considerado como resonante. Además se calculan la transmisibilidad de fuerzas (Ec. 9), el factor de respuesta dinámica de desplazamiento (Ec. 6), el factor de respuesta dinámica de velocidad (Ec. 7) y el factor de respuesta dinámica de aceleración (Ec. 8) correspondiente.

$$TR = \left( \frac{1 + [2\xi(\omega / \omega_n)]}{[1 - (\omega / \omega_n)^2]^2 + [2\xi(\omega / \omega_n)]^2} \right)^{1/2}$$

$$= \left( \frac{1 + [2*0.05*(0.977 / 11.475)]}{[1 - (0.977 / 11.475)^2]^2 + [2*0.05*(0.977 / 11.475)]^2} \right)^{1/2} = 1.012$$

$$R_d = 1.007$$

$$R_v = \frac{\omega}{\omega_n} R_d = \frac{0.977Hz}{11.475Hz} * 1.007 = 0.086$$

$$R_a = \left( \frac{\omega}{\omega_n} \right)^2 R_d = \left( \frac{0.977Hz}{11.475Hz} \right)^2 * 1.007 = 0.007$$

Al realizar el cálculo de los parámetros en estudio, se observa cómo la transmisibilidad de fuerzas presente entre el sismo y el pórtico es 1.012. Además, los factores de respuesta de desplazamiento, de velocidad y de aceleración son 1.007, 0.086 y 0.007, respectivamente. Con estas variables se determina que no se amplifican los efectos causados por el sismo de Los Santos, Santander, Colombia, a la estructura propuesta. Además, analizando la relación de resonancia, se puede concluir que no se necesitará una modificación estructural al pórtico para obtener una respuesta adecuada al sismo, por lo tanto este ejemplo no entrará a la fase 3 ni a la fase 4 de esta investigación, es decir, no pasará por el proceso de la RNA ni ejecutará activación al sistema de control semi-activo.

Por otra parte, los resultados del análisis modal de esta y cualquier estructura que se analice en esta tesis de investigación, son los modos de vibración principales y sus respectivos periodos, los desplazamientos totales de la estructura, la masa modal y los cortantes basales.

Para el pórtico que es ejemplo en este documento se tiene que los periodos de los modos de vibración del 1 al 8 son los siguientes, respectivamente: 11.475 Hz, 34.035 Hz, 55.436 Hz, 74.949 Hz, 91.909 Hz, 105.74 Hz, 115.97 Hz y 122.251 Hz. En cuanto a los modos de vibración de la estructura, se obtiene la Fig. 56 que muestra la masa modal que interactúa en cada modo.




Fig. 56: Gráfica de número de pisos vs. masa modal (normalizada) actuante de la estructura inicial. Fuente: Elaboración propia.

A continuación se muestran los efectos que tienen los dos sismos en estudio con respecto al pórtico analizado. Tal y como se realizó anteriormente, primero se muestran los resultados correspondientes al sismo de Tijuana, México y luego los resultados correspondientes al sismo de Los Santos, Santander, Colombia. La respuesta del desplazamiento de la estructura ante el primer sismo, se muestra en la Fig. 57.





Fig. 57: Gráfica de desplazamiento vs. tiempo, de la estructura inicial con el sismo de Tijuana, México.


Fuente: Elaboración propia.

De igual forma, los cortantes basales que experimenta el pórtico durante el registro sísmico se presentan en la Fig. 58.



*Fig. 58: Cortante basal actuante vs. tiempo, de la estructura inicial con el sismo de Tijuana, México. Fuente: Elaboración propia.*

Los momentos basales que resultan del registro sísmico se presentan en la Fig. 59.



*Fig. 59: Momento basal actuante vs. tiempo, de la estructura inicial con el sismo de Tijuana, México. Fuente: Elaboración propia.*

El desplazamiento provocado por el sismo de Los Santos, Santander, Colombia al pórtico en estudio se muestra en la Fig. 60.




Fig. 60: Gráfica de desplazamiento vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia. Fuente: Elaboración propia.

Los cortantes basales que resultan del registro sísmico se presentan en la Fig. 61.




Fig. 61: Cortante basal actuante vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia. Fuente: Elaboración propia.

De igual forma, los momentos basales que experimenta el pórtico durante el registro sísmico se presentan en la Fig. 62.




Fig. 62: Momento basal actuante vs. tiempo, de la estructura inicial con el sismo de Los Santos, Santander, Colombia. Fuente: Elaboración propia.

### 9.3. Red neuronal artificial RNA

En la fase 3 de esta tesis, se encuentra la red neuronal artificial. Todas las RNA están compuestas por datos de entrada, número de capas ocultas, neuronas en las capas ocultas, pesos sinápticos  $w_{ij}$ , sesgos  $b_{ij}$ , regla de propagación, funciones de activación y datos de salida, que son las variables que realizan la predicción, y por tipo de entrenamiento, función de entrenamiento, y función de cálculo de error, que son los parámetros que intervienen en el aprendizaje y la actualización de la red.

La configuración de la RNA es fundamental para su desarrollo, funcionamiento y rendimiento. Teniendo como referencia el diagrama de flujo de la Fig. 13, el primer paso a realizar es el de recolectar y procesar la información. Este paso ya se realizó con la base de datos producto de un diseño de experimentos en el subcapítulo 9.2 de esta investigación. A continuación con la estructuración y el desarrollo de la red neuronal.

Para el proceso de entrenamiento y determinación de la arquitectura de la red neuronal artificial, los parámetros que se utilizarán como datos de entrada (número de pisos, altura

de los pisos, longitud del vano, área de las columnas, inercia de las columnas, área de las vigas y frecuencia de la estructura) y datos de salida (área de las riostras y la configuración de las riostras) son los correspondientes a la información obtenida en el análisis matricial y el análisis modal del pórtico en estudio, que pertenecen a la base de datos mencionada anteriormente. Una visualización esquemática de la RNA planteada inicialmente en el proceso de entrenamiento y determinación de la red, se presenta en la Fig. 63.

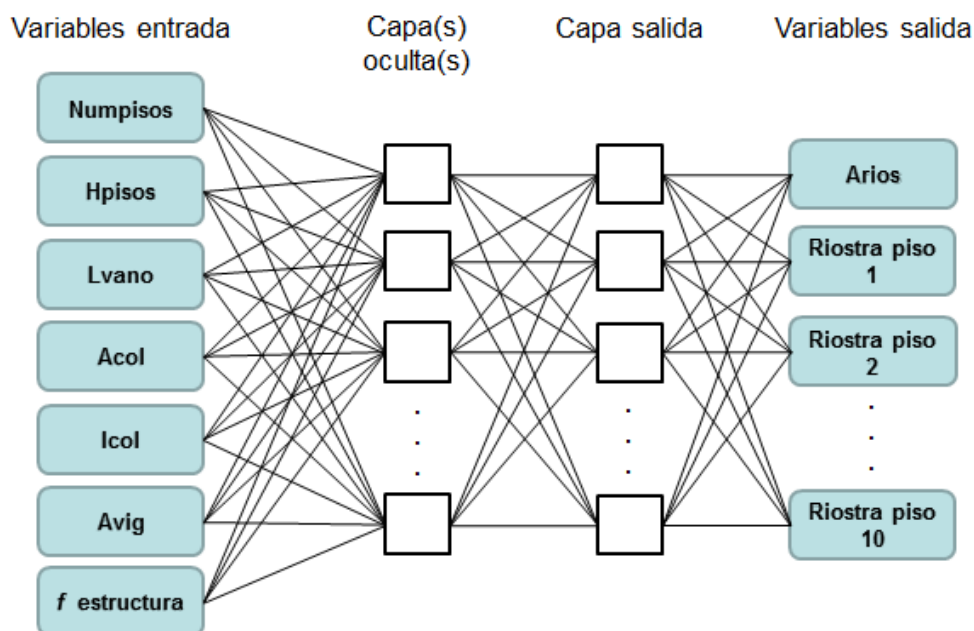


Fig. 63: Esquema inicial planteado para el entrenamiento de la RNA. Fuente: Elaboración propia.

El tipo y la arquitectura de la RNA corresponden a las funciones utilizadas, el número de capas ocultas, el número de neuronas en las capas ocultas y en los parámetros de salida de la red neuronal. El problema que se está estudiando en esta tesis corresponde a un problema de ajuste o función de aproximación. Con esta clasificación, se determina que la configuración práctica para una red neuronal que resuelva el tipo de problema en estudio (Demuth et. al., 2014) es una RNA con una capa oculta con la función sigmoide tangente y una capa de salida con la función lineal como funciones de transferencia de cada capa.

Esta configuración será la arquitectura inicial de la RNA y se le llamará “configuración 0”. Gráficamente, la estructura de la RNA se muestra en la Fig. 64.




Fig. 64: Arquitectura de la configuración 0 de la RNA.

Fuente: Matlab.

Para la determinación del número de neuronas en la capa oculta, expresado como la variable “?” en la Fig. 64, Kubat (2017) expresa que se debe seguir un proceso iterativo en el cual se calcule el número óptimo de neuronas en la capa oculta de la red. En este proceso, también se establece la función de entrenamiento óptima para el caso en estudio. Se realizaron varios procesos de iteración del entrenamiento de la red neuronal, en dónde cambiaran el número de neuronas en la capa oculta (de 5 a 40 neuronas) y la función de entrenamiento (Levenberg-Marquadt LM o regularización bayesiana RB). Se toman 20 ejemplos de cada combinación de número de neuronas con cada función de entrenamiento, y se calculó el promedio del error obtenido *MSE* y el factor de correlación del resultado de la red *R*. La configuración de entrenamiento que se utiliza es el método del descenso del gradiente para calcular la actualización de los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ , se usa el método del error cuadrado medio (*mean square error, MSE*, en inglés) y se realizó una validación cruzada con la proporción 70/15/15 para los datos de entrenamiento, validación y prueba, respectivamente. Así, los resultados de este proceso iterativo, para la configuración 0, se muestran en la Fig. 65 y la Fig. 66 (los datos detallados se encuentran en el Anexo 35).






Fig. 65: Error cuadrático medio MSE de la configuración 0. Fuente: Elaboración propia.




Fig. 66: Factor de correlación R de la configuración 0. Fuente: Elaboración propia.

De la Fig. 65 se observan errores cuadráticos medios pequeños, del orden entre 0.045 y 0.060, en dónde el *MSE* disminuye conforme aumenta el número de neuronas y la regularización bayesiana (RB) presenta mejores resultados que el método Levenberg-Marquadt (LM) como función de entrenamiento. En cuanto al factor de correlación *R* (Fig. 66), se obtienen unos valores buenos, entre 0.855 y 0.875, pero no se consideran satisfactorios, puesto que el criterio para determinar un buen ajuste de datos es con  $R > 0.95$ . Nuevamente, la función de entrenamiento con mejores resultados es la regularización

bayesiana. Para destacar, los entrenamientos calculados con el método de Leverberg-Marquadt (LM) toman mucho menos tiempo en realizar que los hechos con la regularización bayesiana (RB). Además, a mayor número de neuronas en las capas, mayor es el tiempo de duración del entrenamiento.

Con la información obtenida de la configuración 0, se hace necesario implementar técnicas que mejoren los resultados obtenidos, especialmente  $R$  para cumplir con el criterio mencionado anteriormente. Así, se considera utilizar la codificación de los parámetros de salida y la normalización de la información de la base de datos.

La codificación de parámetros de salida se aplica en las variables de ubicación de riostras, para reducir 10 variables a una sola nueva variable y tener una RNA con más variables de entrada que variables de salida. El procedimiento de codificación de la configuración de la ubicación de las riostras se realizó de la siguiente manera: se determinaron todas las posibles combinaciones de existencia de riostras para los pórticos según el número de pisos, empezando por las estructuras de 1 piso y terminando con las de 10 pisos, y se fueron enumerando cada una de estas combinaciones según el orden de incidencia de las riostras en la respuesta estructural (Fig. 67).




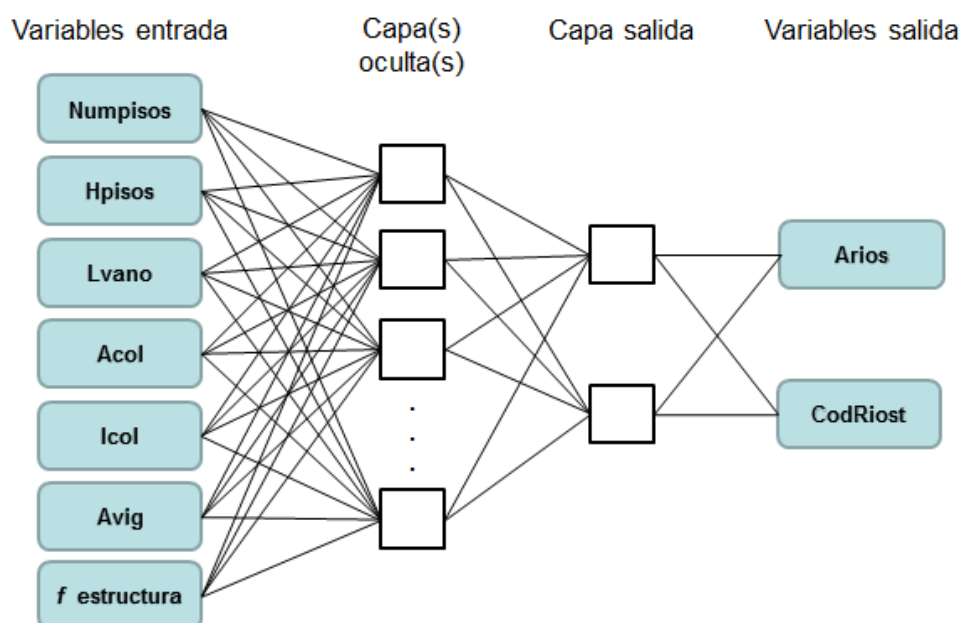
Fig. 67: Proceso de codificación de configuraciones de riostras. Fuente: Elaboración propia.

En la Fig. 67 se muestran las primeras 6 configuraciones para las riostras que pueden tener los pórticos de 1 a 10 pisos. Como se había mencionado anteriormente, se comienza determinando las diversas configuraciones para estructuras de 1 piso, que este caso serían el pórtico sin riostra y el pórtico con riostras en el primer piso. A estas configuraciones se les asignan los códigos 1 y 2 respectivamente. A continuación, se realiza el estudio de las combinaciones posibles para estructuras de 2 pisos, las cuales serían el pórtico sin riostras, el pórtico con riostras en uno de los dos pisos y el pórtico con riostras en los dos pisos. Para determinar el orden de importancia entre las dos posibilidades de riostras en un solo piso

del pórtico (riostras en el primer piso o riostras en el segundo piso), se toma el criterio de verificar la influencia de los arriostramientos en la frecuencia de la estructura. En las estructuras aporticadas, los arriostramientos en los pisos inferiores tienen más influencia en la frecuencia que en los pisos superiores, por lo tanto, en este caso, el pórtico con riostras en el segundo piso se enlista primero que el pórtico con riostras en el primer piso. De esta manera, para los pórticos de dos pisos las configuraciones de riostras se organizan de la siguiente manera: pórtico sin riostras, pórtico con riostras en el segundo piso, pórtico con riostras en el primer piso y pórtico con riostras en el primer y en el segundo piso. Así, se asignan los códigos 3, 4, 5 y 6 respectivamente para las configuraciones explicadas.

Con esta metodología y este criterio, se siguen enumerando los códigos de las configuraciones de las riostras para los pórticos de 3 pisos hasta los pórticos de 10 pisos. La codificación completa se encuentra en Anexo 23 y Anexo 34.

Respecto a la normalización de la base de datos, se realizó conforme a la Ec. 74, obteniendo así todos los datos positivos y normalizados con respecto a la norma del vector del parámetro correspondiente. El resultado de este proceso de normalización también se encuentra en el Anexo 34. La nueva estructura de la RNA se presenta en Fig. 68.



*Fig. 68: Nuevo esquema para el entrenamiento de la RNA. Fuente: Elaboración propia.*

Luego de utilizar estas dos técnicas para el mejoramiento de los resultados de la RNA, se procede a realizar otra vez el entrenamiento de la red neuronal artificial bajo las nuevas condiciones tenidas en cuenta. Para este entrenamiento, se tomará la misma estructura de configuración 0 y se cambiará el número de variables de salida, debido a la codificación hecha. A esta RNA, se le llamará “configuración 1” y gráficamente está compuesta por lo mostrado en la Fig. 69. Nuevamente, la variable del número de neuronas en la capa oculta está representado como la variable “?”.

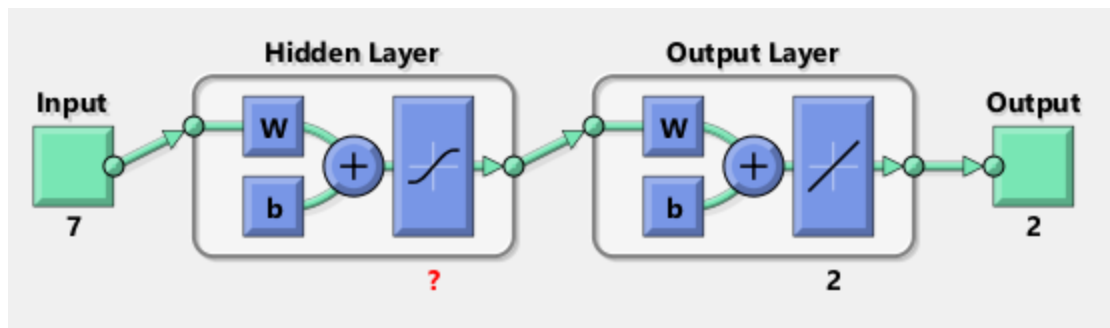


Fig. 69: Arquitectura de la configuración 1 de la RNA.

Fuente: Matlab.

Realizando el proceso de entrenamiento descrito anteriormente, se obtienen los siguientes resultados (Fig. 70 y Fig. 71).





Fig. 70: Error cuadrático medio MSE de la configuración 1. Fuente: Elaboración propia.



*Fig. 71: Factor de correlación  $R$  de la configuración 1. Fuente: Elaboración propia.*

Comparando la Fig. 65 y la Fig. 70, se observa una gran mejoría en el resultado del error cuadrático medio, que pasó de un rango de 0.045 y 0.060 a uno de 0.000060 y 0.000085, lo cual es una disminución considerable. Haciendo un análisis de las figuras Fig. 66 y Fig. 71, también se encuentra una mejoría en los datos del factor de correlación, en dónde la configuración 1 tiene valores de  $R$  entre 0.905 y 0.935. Esto indica que las técnicas de codificación de variables y normalización de datos fueron efectivas para el mejoramiento de los resultados del entrenamiento. Además, se puede observar el comportamiento del  $MSE$  con respecto al número de neuronas por capas, descrito por Kubat (2017) y se evidencia en la Fig. 11. Para verlo gráficamente, los análisis realizados anteriormente se muestran en las figuras Fig. 72 y Fig. 73.




Fig. 72: Comparación del error cuadrático medio MSE de la configuración 0 y 1. Fuente: Elaboración propia.




Fig. 73: Comparación del factor de correlación R de la configuración 0 y 1. Fuente: Elaboración propia.

Aunque se tiene una mejora de los resultados con la configuración 1, todavía se encuentra que no cumple con el criterio  $R > 0.95$ , por lo tanto, es necesario determinar si alguna otra configuración posible para la arquitectura de la red neuronal puede cumplir con este requerimiento. De esta forma, se plantean distintas configuraciones de RNA, variando el número de capas, el número de neuronas por capas, las funciones de activación y las funciones de entrenamiento.

En esta investigación, los parámetros para determinar qué configuraciones tienen resultados deseados son: redes neuronales con 2 y 3 capas, 10 neuronas por capa, las funciones de activación sigmoide logarítmica (logsig), sigmoide tangente (tansig) y lineal (purelin) mostradas en la Tabla 1, y las funciones de entrenamiento de Levenberg-Marquadt (LM). El estudio consistió en realizar 5 entrenamientos de todas las combinaciones para conocer un valor promedio estimado de  $MSE$  y  $R$ , en dónde los criterios de selección para un estudio más profundo son  $MSE < 0.0001$  y  $R > 0.90$ . Así, los datos de este estudio se encuentran en la Tabla 6 y la Tabla 7, que corresponden a redes neuronales con 2 y 3 capas respectivamente.

*Tabla 6: Combinaciones de arquitecturas para RNA de 2 capas y resultados de MSE y R. Fuente: Elaboración propia.*

<b>Combinación</b>	<b>Capa oculta</b>	<b>Capa de salida</b>	<b>MSE estimado</b>	<b>R estimado</b>	<b>Decisión</b>
Comb1	logsig	logsig	0.000519	0.67238	NO
Comb2	purelin	logsig	0.000488	0.67684	NO
Comb3	tansig	logsig	0.000476	0.71272	NO
Comb4	logsig	purelin	0.000080	0.90955	SI
Comb5	purelin	purelin	0.000177	0.79235	NO
Comb6	tansig	purelin	0.000100	0.91367	SI
Comb7	logsig	tansig	0.000083	0.92068	SI
Comb8	purelin	tansig	0.000122	0.85487	NO
Comb9	tansig	tansig	0.000080	0.92099	SI

*Tabla 7: Combinaciones de arquitecturas para RNA de 3 capas y resultados de MSE y R. Fuente: Elaboración propia.*

<b>Combinación</b>	<b>Capa oculta 1</b>	<b>Capa oculta 2</b>	<b>Capa de salida</b>	<b>MSE estimado</b>	<b>R estimado</b>	<b>Decisión</b>
Comb1	logsig	logsig	logsig	0.000515	0.60800	NO
Comb2	purelin	logsig	logsig	0.000516	0.68066	NO
Comb3	tansig	logsig	logsig	0.000524	0.67824	NO
Comb4	logsig	purelin	logsig	0.000528	0.60253	NO
Comb5	purelin	purelin	logsig	0.000530	0.68073	NO
Comb6	tansig	purelin	logsig	0.000512	0.67089	NO
Comb7	logsig	tansig	logsig	0.000496	0.71743	NO
Comb8	purelin	tansig	logsig	0.000476	0.68835	NO
Comb9	tansig	tansig	logsig	0.000497	0.67390	NO

Comb10	logsig	logsig	purelin	0.000091	0.92341	SI
Comb11	purelin	logsig	purelin	0.000088	0.90655	SI
Comb12	tansig	logsig	purelin	0.000068	0.93007	SI
Comb13	logsig	purelin	purelin	0.000103	0.90939	NO
Comb14	purelin	purelin	purelin	0.000171	0.79320	NO
Comb15	tansig	purelin	purelin	0.000100	0.90465	SI
Comb16	logsig	tansig	purelin	0.000097	0.92287	SI
Comb17	purelin	tansig	purelin	0.000106	0.91290	NO
Comb18	tansig	tansig	purelin	0.000123	0.91478	NO
Comb19	logsig	logsig	tansig	0.000086	0.92162	SI
Comb20	purelin	logsig	tansig	0.000070	0.91784	SI
Comb21	tansig	logsig	tansig	0.000075	0.92353	SI
Comb22	logsig	purelin	tansig	0.000091	0.91135	SI
Comb23	purelin	purelin	tansig	0.000121	0.85517	NO
Comb24	tansig	purelin	tansig	0.000084	0.91538	SI
Comb25	logsig	tansig	tansig	0.000086	0.92442	SI
Comb26	purelin	tansig	tansig	0.000078	0.92418	SI
Comb27	tansig	tansig	tansig	0.000098	0.92531	SI

Con la información obtenida en las tablas Tabla 6 y Tabla 7 se pueden tomar en cuenta varias configuraciones arquitectónicas para las redes neuronales artificiales. De las combinaciones descritas anteriormente se tomarán las mencionadas a continuación para determinar si alguna cumple con el criterio de  $R > 0.95$ :

- Combinación 6 de RNA de 2 capas, se denominará “configuración 1” (estudiada anteriormente, resultados en las figuras Fig. 70 y Fig. 71).
- Combinación 7 de RNA de 2 capas, se denominará “configuración 2”.
- Combinación 9 de RNA de 2 capas, se denominará “configuración 3”.
- Combinación 12 de RNA de 3 capas, se denominará “configuración 4”.
- Combinación 16 de RNA de 3 capas, se denominará “configuración 5”.
- Combinación 21 de RNA de 3 capas, se denominará “configuración 6”.

Con estas nuevas configuraciones, se realizan 20 procesos de entrenamientos por cada nivel de número de neuronas por capa y cada función de entrenamiento para determinar los valores promedios de  $MSE$  y  $R$ . Las figuras Fig. 74 y Fig. 75 muestran estos resultados y la información detallada se encuentra en el Anexo 35.






Fig. 74: Comparación del error cuadrático medio MSE de las configuraciones 1 a 6. Fuente: Elaboración propia.




Fig. 75: Comparación del factor de correlación R de las configuraciones 1 a 6. Fuente: Elaboración propia.

De todas estas configuraciones de las redes neuronales artificiales, la configuración 6 compuesta por 3 capas de neuronas, con 2 capas ocultas de 15 neuronas cada una y una capa de salida de 2 neuronas, cuyas funciones de activación son sigmoide tangente (tansig), sigmoide logarítmica (logsig) y sigmoide tangente (tansig), respectivamente, y el método de la regularización bayesiana como método de entrenamiento, resulta con buenos

resultados de error cuadrático medio ( $MSE = 0.0000107$ ) y el mayor factor de correlación ( $R = 0.95862$ ). A pesar de que esta misma configuración tiene mejores datos de  $MSE$  y  $R$  con mayor número de neuronas por capa, el gasto computacional de recursos y de tiempo hace que estas opciones no sean óptimas. En este caso, para las RNA de 15 neuronas, el tiempo de realización de un ciclo de entrenamiento es aproximadamente de 30 segundos, en cambio para 40 neuronas, la duración del entrenamiento es de aproximadamente 30 minutos, todo esto en un computador portátil con un procesador Intel Core i7-4510U de 2.00 GHz-2.60 GHz, con una memoria RAM de 8.00 GB y un sistema operativo de 64 bits. De esta forma se tiene definida la arquitectura y la configuración de la red neuronal artificial (Fig. 76).




Fig. 76: Arquitectura escogida para la RNA. Fuente: Elaboración propia.

A partir de la configuración escogida y los parámetros de número de neuronas y función de entrenamiento determinados, se realizan procesos de entrenamiento adicionales para encontrar los valores óptimos de los pesos sinápticos  $w_{ij}$  y los sesgos  $b_{ij}$ , y se ejecuta una prueba de predicción para determinar el error específico que tiene la RNA seleccionada. Esto se realizó con 10 entrenamientos diferentes de la red neuronal artificial elegida, en el que se tomaron 20 ejemplos aleatorios de la base de datos y predecir el valor

correspondiente. Luego, se realizó el cálculo del error relativo del valor real y del valor predicho, considerando satisfactorio un error relativo menor al 10.0 %. Para una mejor comprensión de los datos, se grafican los histogramas de frecuencias de error (Fig. 77 y Fig. 78). La información detallada de este proceso está en el Anexo 36.




Fig. 77: Histograma de errores de predicción de la variable área de riostras de todos los entrenamientos.

Fuente: Elaboración propia.




Fig. 78: Histograma de errores de predicción de la variable código de riostras de todos los entrenamientos.

Fuente: Elaboración propia.

De los histogramas de errores de la variable *Arios* (Fig. 77), se puede observar un buen comportamiento de precisión al momento de realizar la predicción, ya que aproximadamente el 80.0 % de los datos presenta un error menor al 10.0 %. Con respecto a los histogramas de errores de la variable *CodRiost* (Fig. 78), el porcentaje de datos que se encuentran en el rango de error menor al 10.0 % disminuye bastante y se encuentra una mayor distribución de las predicciones en el resto de rangos. Esto ocurre porque los datos de la variable *CodRiost* son muy pequeños, del orden de magnitud de  $1 \times 10^{-5}$ , y cualquier diferencia en la predicción es significativa para el porcentaje de error. Es necesario recordar que sólo se están tomando 20 datos para hacer estos histogramas, y que en general, el *MSE* aproximado es 0.00001 y el *R* es mayor a 0.95, por lo que es normal que realizando las predicciones de toda la información de la base de datos, los porcentajes de datos con error menor al 10.0 % aumenten para ambas variables.

Entre todos los entrenamientos realizados, se observó que el ajuste del entrenamiento 10 de la RNA tiene un mayor porcentaje de datos dentro del rango de error aceptado en ambas variables en estudio (Fig. 77 y Fig. 78). Por tal motivo, se selecciona esa red neuronal en particular para realizar la predicción del ejemplo de esta investigación.




Fig. 79: Histograma de errores de predicción de la variable área de riostras del entrenamiento 10. Fuente: Elaboración propia.




Fig. 80: Histograma de errores de predicción de la variable código de riostras del entrenamiento 10. Fuente: Elaboración propia.

De la Fig. 79, se observa que el entrenamiento seleccionado tiene un 90.0 % de datos con un error menor al 10.0 %, el porcentaje restante se divide en 5.0 % en el rango de error

entre 10.0 % y 20.0 %, y 5.0 % en el rango de error entre 40.0 % y 50.0 %. Con respecto a la Fig. 80, los porcentajes se distribuyen de 45.0 %, 10.0 % y 45.0 % entre los rangos de error menor a 10.0 %, entre 20.0 % y 30.0 % y más de 50.0 %, respectivamente. Este comportamiento, ya explicado anteriormente, se debe por la magnitud de los datos de la variable.

Además de revisar los histogramas de errores de la predicción en las variables, también se ha verificado el criterio de predicción de la configuración de riostras. Se hizo un histograma (Fig. 81) en el que se muestra el número de riostras a utilizar según las predicciones realizadas por la RNA. Se observa que el 55.0 % de las predicciones utilizan 3 riostras o menos en toda la estructura, en cambio, sólo se tiene un 20.0 % que utilizan más de 5 riostras. Esto demuestra que la RNA está buscando una solución con el menor número de riostras posibles para activar.




Fig. 81: Histograma de número de riostras predichas del entrenamiento 10. Fuente: Elaboración propia.

Luego de determinar la mejor configuración posible para la red neuronal artificial, comprobar el buen rendimiento y aprobar los criterios de predicción de la RNA, se procede a utilizar la red (Fig. 76) para realizar el cálculo de la configuración estructural deseada. En

esta fase de uso y predicción de la RNA, se tendrán en cuenta las variables de entrada y de salida que se consideraron en la fase de entrenamiento, excepto la variable frecuencia de estructura, que cambiará a frecuencia requerida de la nueva estructura ( $f_{req}$ ), que consiste en la multiplicación de la frecuencia de la estructura por un factor de 1.65 para evitar la resonancia (descrito en la Sección 8.3).

Cabe resaltar, que el uso y la predicción de la RNA que se está mostrando en esta sección corresponde a la interacción de la estructura propuesta con el sismo de Tijuana, México, ya que como se determinó en el subcapítulo 8.2, las frecuencias de la estructura y del sismo de Los Santos, Santander, Colombia, no se encuentran en resonancia. Por lo tanto, no se presenta una modificación estructural en el pórtico para ese ejemplo y no se realizarán cálculos comparativos.

En resumen, esta RNA está estructurada de la siguiente manera (entre paréntesis se encuentra el valor del parámetro para el ejemplo analizado):

- Datos de entrada: Número de pisos (8), altura de pisos (3.50 m), longitud de vano entre columnas (6.50 m), área de columnas ( $0.0159 \text{ m}^2$ , HEA400), inercia de columnas ( $0.0004507 \text{ m}^4$ , HEA400), área de vigas ( $0.00845 \text{ m}^2$ , IPE400) y frecuencia requerida del pórtico (18.934 Hz).
- Número de capas ocultas: 3.
- Número de neuronas por capas: 15.
- Pesos sinápticos  $w_{ij}$  y sesgos  $b_{ij}$ : Se presentan en el Anexo 26.
- Regla de propagación:  $w_{ij} * X + b_{ij}$ .
- Funciones de activación: Para la primera capa oculta de neuronas se utiliza la función sigmoide tangente hiperbólica, para la segunda capa oculta de neuronas se utiliza la función sigmoide logarítmica y para la capa de salida se utiliza la función sigmoide tangente hiperbólica.
- Función de costo de error: error cuadrado medio,  $MSE$ .
- Función de entrenamiento: regularización bayesiana (RB).
- Datos de salida: el área de las riostras y código de las riostras en la estructura.

La representación gráfica de la red neuronal artificial desarrollada se presenta en la Fig. 82.




Fig. 82: Red neuronal artificial para predicción. Fuente: Elaboración propia.

El esquema anteriormente presentado (Fig. 82) se muestra con los valores reales de los parámetros considerados para la RNA. Para un mejor funcionamiento de la red neuronal, se realiza la normalización de la base de datos utilizada para el entrenamiento de la red y las variables para la predicción. Esta normalización se realiza bajo la Ec. 74. Se debe destacar que la predicción de la RNA se muestra en valores normalizados, por lo que se multiplicó por el inverso de la Ec. 74 para obtener el valor real de los parámetros. Después de todo el proceso matemático de la RNA, se obtuvo que el área de las riostras es  $0.0054 \text{ m}^2$  y que el código de las riostras es el 1927, con el cual corresponde a que las riostras deben localizarse en los pisos 1, 2, 3 y 7 de la estructura. En este caso, el área calculada de la riostra corresponde a un perfil con sección comercial, PTE  $200 \times 200 \times 7.0$ . Cuando no ocurra esta situación, se realizará una aproximación del área calculada por la red neuronal al área más cercana de un PTE comercial existente. De esta forma, la nueva estructura queda configurada como se muestra en la Fig. 83.






Fig. 83: Estructura modificada por sistema de control. Fuente: Elaboración propia.

Con este cambio en la configuración del área y de la ubicación de las riostras, se hace necesario que se verifique el nuevo comportamiento de la estructura con el análisis matricial y el análisis modal. Esto se realiza a partir de la fase 2 de esta tesis (subcapítulo 9.2), en la cual se toman los datos de entrada y los datos de salida de la red neuronal artificial para calcular el periodo fundamental del pórtico, cuyo resultado es 16.377 Hz. Se determina si existe resonancia de la nueva estructura y el sismo:

$$Res = \frac{f_{domsismo}}{f_{fundestr}} = \frac{8.984}{16.377} = 0.549$$

Retomando el criterio elegido para establecer la existencia de la resonancia, se revisa el cálculo de las frecuencias de resonancia y la transmisibilidad de fuerzas (Ec. 9, Ec. 10, Ec. 11 y Ec. 12). También se calculan los factores de respuesta dinámicos de desplazamiento, de velocidad y de aceleración (Ec. 6, Ec. 7 y Ec. 8).

$$\omega_{dRes} = \omega_n \sqrt{1-2\xi^2} = 16.377 * \sqrt{1-2(0.05)^2} = 16.336$$

$$\omega_{vRes} = \omega_n = 16.377$$

$$\omega_{aRes} = \frac{\omega_n}{\sqrt{1-2\xi^2}} = \frac{16.377}{\sqrt{1-2(0.05)^2}} = 16.418$$

$$TR = \left( \frac{1 + [2\xi(\omega / \omega_n)]}{[1 - (\omega / \omega_n)^2]^2 + [2\xi(\omega / \omega_n)]^2} \right)^{1/2}$$

$$= \left( \frac{1 + [2 * 0.05 * (8.984 / 16.377)]}{[1 - (8.984 / 16.377)^2]^2 + [2 * 0.05 * (8.984 / 16.377)]^2} \right)^{1/2} = 1.465$$

$$R_d = 1.327$$

$$R_v = \frac{\omega}{\omega_n} R_d = \frac{8.984Hz}{16.377Hz} * 1.327 = 0.728$$

$$R_a = \left( \frac{\omega}{\omega_n} \right)^2 R_d = \left( \frac{8.984Hz}{16.377Hz} \right)^2 * 1.327 = 0.399$$

De los anteriores cálculos, se puede concluir que la nueva configuración estructural no incurre en el fenómeno de resonancia con el registro sísmico en estudio, por lo cual los factores de respuesta dinámicos son satisfactorios para no tener las grandes amplificaciones de efectos que se tenían con la estructura inicial.

Además, se calculan los modos de vibraciones principales, sus respectivas frecuencias (16.377 Hz, 53.19 Hz, 72.951 Hz, 85.055 Hz, 110.547 Hz, 183.958 Hz, 228.464 Hz,

261.553 Hz) y la masa modal actuante en cada modo (Fig. 84), los desplazamientos totales de la estructura (Fig. 85), los cortantes basales (Fig. 86) y los momentos basales (Fig. 87) para conocer la variación de estos parámetros con respecto al primer pórtico analizado.




Fig. 84: Gráfica comparativa de número de pisos vs. masa modal actuante (normalizada), de la estructura inicial y la estructura final. Fuente: Elaboración propia.




Fig. 85: Gráfica comparativa de desplazamiento vs tiempo, de la estructura inicial y la estructura final. Fuente: Elaboración propia.




Fig. 86: Gráfica comparativa de cortante basal actuante vs tiempo, de la estructura inicial y la estructura final. Fuente: Elaboración propia.




Fig. 87: Gráfica comparativa de momento basal actuante vs tiempo, de la estructura inicial y la estructura final. Fuente: Elaboración propia.

Los resultados de las gráficas anteriormente mostradas (Fig. 85, Fig. 86 y Fig. 87), evidencian una importante disminución en los parámetros de desplazamiento en la base, cortante basal y momento basal, respectivamente. Comparando el desplazamiento en la

base de las estructuras sin control y con control, se observa una reducción entre 40.0 % y 60.0% en el primer modo de vibración, que resulta el modo más importante para este tipo de estructuras. En cuanto a los cortantes basales y los momentos basales experimentados por el pórtico con la configuración propuesta por la red neuronal artificial, la disminución de estos parámetros está entre el 30.0 % y el 50.0 % de los valores de la configuración estructural inicial. Con esta mejoría de las variables estudiadas, se considera que la red neuronal artificial ha cumplido su objetivo y ha determinado una configuración estructural idónea para un pórtico que está sometido a un sismo específico.

#### **9.4. Sistema de control**

Por último, realizando la fase final de esta tesis y como resultado del estudio detallado de la literatura especializada en el tema, se va a determinar la mejor opción entre los diversos sistemas de control que existen para utilizar como mecanismo ante cargas sísmicas que afecten la estructura. Esto se hace con el fin de implementar la red neuronal artificial y darle aplicabilidad a la investigación realizada. Cabe destacar, que en el alcance de esta tesis no está el diseñar el dispositivo físico que actúa como el sistema de control en sí, sino presentar una posibilidad idónea para el control sísmico.

Haciendo un resumen sobre los sistemas de control que se usan actualmente, las tres grandes categorías que se tienen son las siguientes: pasivos (Fig. 20), activos (Fig. 26) y semi-activos (Fig. 29). Para formar un criterio y realizar una elección correcta sobre el sistema de control, hay que conocer las ventajas y las desventajas de estos mecanismos. La característica principal de los sistemas activos es la eficiencia de las acciones de estos dispositivos, pero tienen el problema de necesitar una fuente constante de suministro energía para su funcionamiento. Por otra parte, los sistemas pasivos trabajan sin una fuente de energía grande y/o estable, pero requieren de suficiente espacio para ubicar el aparato que actúa.

Para aprovechar las ventajas y disminuir las desventajas de ambos tipos de sistemas de control, una decisión sensata es analizar el comportamiento de los sistemas semi-activos. De los mecanismos investigados en esta tesis se tienen los siguientes: dispositivos de control de rigidez (Fig. 30), amortiguadores electroreológicos (Fig. 31), amortiguadores

magnetoreológicos (Fig. 32), dispositivos de control de fricción, amortiguadores de fluido viscoso y, amortiguadores de masa sincronizada (Fig. 33) y de líquido sincronizado (Fig. 25).

Luego de revisar las ventajas y las desventajas de cada uno de estos sistemas, se decidió utilizar dispositivos amortiguadores magnetoreológicos para accionarlos con la red neuronal artificial creada. Los motivos de esta elección son el bajo consumo de energía (la fuente de energía puede ser una batería de 9V), la sencillez de funcionamiento, la capacidad de adaptación al tipo de riostra empleada en la estructura, el rápido tiempo de respuesta (entre 1 y 3 ms) y la facilidad económica para crearlo o comprarlo. La desventaja de esta elección radica en su accesibilidad tecnológica, debido a que no es un dispositivo tan común como otros.

Fisco & Adeli (2011) explican que este tipo de sistema de control semi-activo se compone de un cilindro de fluido viscoso que reacciona ante campos magnéticos, un pistón, unos cables que conducen energía eléctrica y una bobina que genera los campos magnéticos. En cuanto a su funcionamiento, la bobina regula cuánto voltaje recibe el fluido magnetoreológico, modificando su viscosidad y su coeficiente de amortiguamiento en tiempo real. Cuando no hay energía eléctrica, este tipo de amortiguadores funciona como amortiguadores pasivos, utilizando el mecanismo llamado falla segura.

Winthrop (2004), Hu (2012) y Salem (2014) proponen diversos sistemas de control con variación de la rigidez aplicando algoritmos diferentes para la acción del motor y de la válvula. Por otra parte, Hu (2012) propone un algoritmo para controlar los amortiguadores magnetoreológicos a través de la aplicación de campos magnéticos que recrean el modelo de histéresis de Bouc-Wen, el cuál determina y predice la respuesta controlada de todo el sistema a partir de varios parámetros estructurales.

Este último sistema de control semi-activo con dispositivos de control de rigidez resulta ser el más adecuado para la red neuronal artificial desarrollada en esta tesis. Esto se debe a que la misma RNA, activa o desactiva la válvula de control para cambiar la configuración estructural del pórtico mediante las riostras, cumpliendo con el criterio del cociente entre la frecuencia del sismo y la frecuencia de la estructura. Para tal fin, todas las riostras de la

estructura deben estar adaptadas con este sistema y el modelo estructural de dicha configuración debe estar registrado previamente en la base de datos de la red neuronal.

### 9.5. Estrategia de control e implementación práctica

Teniendo definidas todas las metodologías y los procesos realizados por los algoritmos para llevar a cabo adecuadamente el sistema de control, se define la estrategia de control desarrollada (Fig. 88).

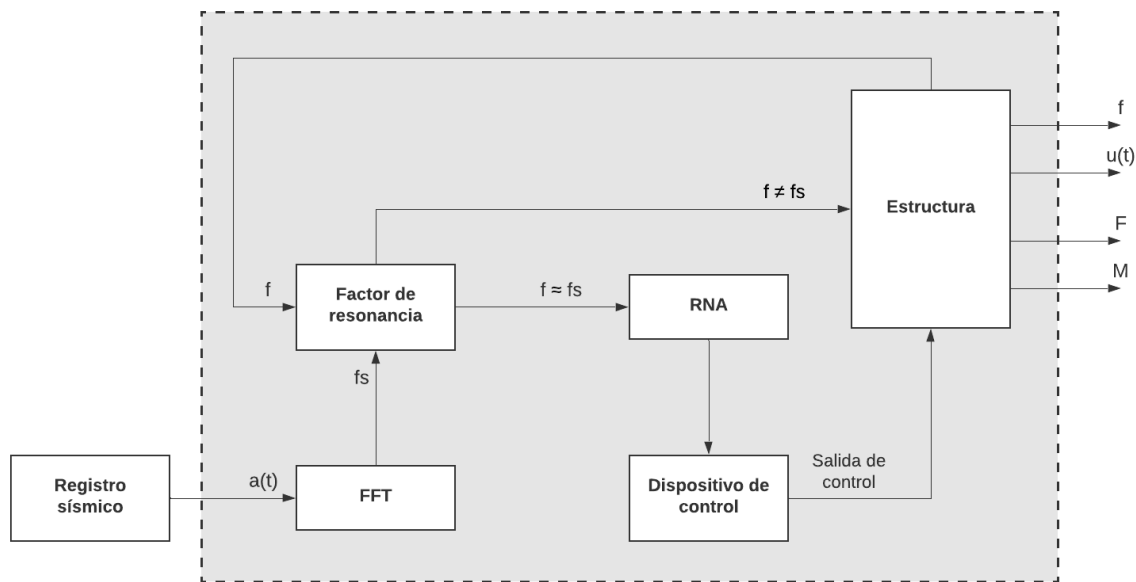


Fig. 88: Diagrama de bloques de la estrategia de control. Fuente: Elaboración propia.

Inicialmente, se presenta la ocurrencia de un registro sísmico, el cual se cuantifica mediante la aceleración a través del tiempo durante el suceso. Esta información se procesa matemáticamente con las transformadas de Fourier (FFT) para determinar la frecuencia predominante del sismo. La frecuencia calculada se compara con la frecuencia de la estructura que está siendo afectada por el sismo.

Si estas frecuencias resultan similares (dentro del intervalo determinado en subcapítulos anteriores), el sistema de control usa una red neuronal artificial para predecir una decisión que evite que siga ocurriendo el fenómeno de la resonancia. Posteriormente, esta decisión pasa al dispositivo de control previamente escogido, y ejecuta una acción de control para

modificar la configuración estructural del pórtico afectado. Esta acción de control se ve reflejada en un cambio de los siguientes parámetros experimentados por la estructura: frecuencia fundamental, desplazamientos, cortante basal y momento basal.

Si las frecuencias comparadas no son similares, no se produce un procesamiento de la RNA ni una acción de control. Es decir, no existe una modificación estructural del pórtico, al cual se siguen monitoreando los parámetros de frecuencia fundamental, desplazamientos, cortante basal y momento basal.

Para realizar la implementación práctica de la metodología descrita y obtener los resultados mostrados anteriormente, se presenta el siguiente diagrama de flujo (Fig. 89) en el cuál se explican paso a paso los procedimientos y decisiones tomados por el algoritmo que define el sistema de control sísmico semi-activo a través de las redes neuronales artificiales.

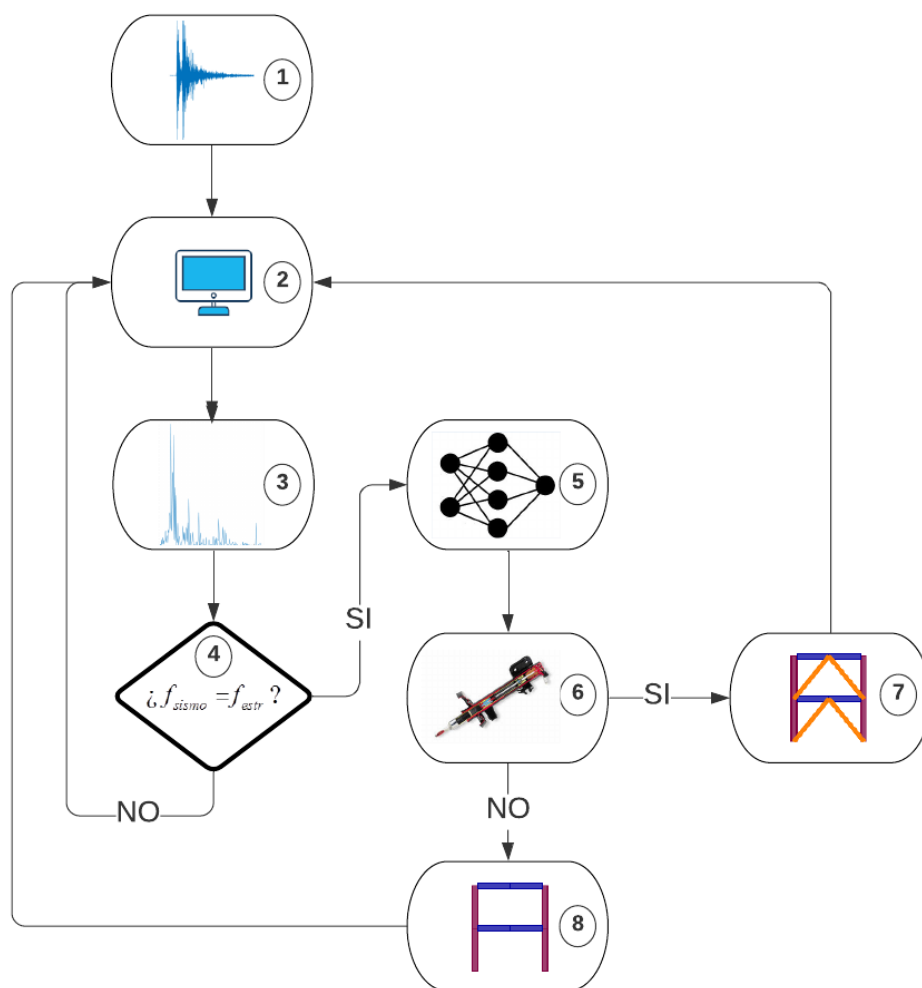


Fig. 89: Diagrama de flujo del algoritmo del sistema de control. Fuente: Elaboración propia.



Como se observa en la Fig. 89, el primer paso es la existencia de una actividad sísmica que afecte la estructura (1). Esta actividad sísmica será registrada por un acelerograma que estará conectado a un computador (2) que tendrá una rutina ejecutable desarrollada en *Matlab* que comprende el algoritmo del sistema de control presentando en esta investigación. Posteriormente, esa señal sísmica es procesada matemáticamente por el algoritmo a través del análisis de dominio de frecuencias (3), usando las transformadas de Fourier, determinando la frecuencia predominante del sismo cada 1.0 s para monitorear constantemente el comportamiento de esta variable.

Luego, se hace la verificación de la existencia de la resonancia entre el sismo y la estructura (4): si no se encuentra resonancia, el algoritmo seguirá recibiendo y procesando el registro sísmico existente (2). Por el contrario, si se encuentra resonancia, el algoritmo procede a utilizar la RNA (5) para predecir una configuración estructural que cambie las propiedades dinámicas del pórtico y se evite el fenómeno de amplificación de esfuerzos por la resonancia.

La predicción de la RNA se convierte en la señal de activación y en el criterio de funcionamiento para el sistema de control semi-activo mediante amortiguadores magnetoreológicos (6). Al activarse este sistema de control, se ejecuta la decisión de configuración estructural predicha por la red (7) y se procede a verificar nuevamente la resonancia entre el sismo y la estructura (4). Si se sigue presentando resonancia, se repite la predicción de la RNA (5) y la activación de los amortiguadores (6) magnetoreológicos correspondientes. Dependiendo de configuración estructural predicha, se cambia la ubicación de las riostras nuevamente (7) o se mantiene la acción de decisión anteriormente mencionada (8). Este ciclo se ejecuta hasta que finalice el sismo (1).

## **10. CONCLUSIONES**

Esta investigación desarrolla un sistema efectivo para realizar un control sísmico semi-activo utilizando redes neuronales artificiales. La correcta interacción de un análisis del dominio de frecuencias, un análisis matricial, un análisis modal, una RNA y un sistema de control adecuado permiten lograr el Objetivo general de esta tesis, encontrando una solución óptima al problema planteado.

El análisis de dominio de frecuencias, implementando la teoría de las transformadas de Fourier, obtiene de manera rápida y sencilla la frecuencia dominante del sismo, que corresponde a la frecuencia con mayor amplitud espectral dentro de una señal, realizando una buena caracterización del comportamiento del sismo estudiado.

Se reafirma que el análisis matricial y el análisis modal, describen las propiedades físicas y dinámicas de cualquier estructura que se desee estudiar. Se calcula la frecuencia fundamental de la estructura y se compara con la frecuencia dominante del sismo para determinar la existencia del fenómeno de resonancia.

Las redes neuronales artificiales son la parte más importante de esta tesis, debido a que resuelven matemáticamente el problema estudiado. Al proponer una buena estructura para la RNA (variables de entrada, número de capas ocultas, número de neuronas en las capas, funciones de activación, de entrenamiento y de error, variables de salida, etc.), en conjunto con una buena base de datos y un proceso de entrenamiento adecuado, se puede predecir cualquier tipo de información. En este caso, se predicen con precisión el área de la riostra y la configuración de riostras, bajo el criterio de menor área de sección y menor número de riostras necesarias, que necesita la estructura para tener una frecuencia fundamental que difiera a la frecuencia dominante de la señal sísmica.

Los amortiguadores magnetoreológicos son dispositivos de control de rigidez y se escogieron como la solución ideal del sistema de control semi-activo. Esta elección se debe a sus múltiples ventajas como el constante monitoreo de la estructura, el bajo consumo de energía requerido, sus dimensiones, el bajo costo de implementación, la rapidez de la respuesta y el buen mecanismo de activación o desactivación de riostras que cambien las propiedades dinámicas del pórtico en estudio, según la decisión emitida por la red neuronal artificial.

De esta forma, se obtiene con éxito un sistema de control con redes neuronales artificiales que modifica la configuración estructural de un pórtico 2D para que no experimente resonancia con la frecuencia dominante de un registro sísmico.

Esta tesis sienta las bases para la investigación de más aplicaciones de sistemas de control con redes neuronales artificiales. Se pueden desarrollar más trabajos para ampliar el alcance de los objetivos establecidos en este documento, por ejemplo, la implementación del análisis matricial y el análisis modal para estructuras en 3D, ampliación de la base de datos para la RNA, diseño del sistema de control, entre otros, con el fin de conseguir un aplicación práctica real de esta metodología desarrollada.

## 11. REFERENCIAS

- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-94463-0>
- Ahmad, Z., Mat Noor, R. 'Adawiah, & Zhang, J. (2009). Multiple neural networks modeling techniques in process control: A review. *Asia-Pacific Journal of Chemical Engineering*, 4(4), 403–419. <https://doi.org/10.1002/apj.213>
- Ahmadi, N., Moghadas, R. K., & Lavaei, A. (2008). Dynamic analysis of structures using neural networks. *American Journal of Applied Sciences*, 5(9), 1251–1256. <https://doi.org/10.3844/ajassp.2008.1251.1256>
- AIS. (2010). *Reglamento Colombiano de Construcción Sismo Resistente*.
- Amrouche, A., & Rouvaen, J. M. (2006). Efficient system for speech recognition using general regression neural network. *International Journal of Computer Systems Science and Engineering*, 1(2), 183–189.
- Arcila, J., Riveros, C., & Riveros, J. (2014). *Optimización de secciones de vigas y columnas para el cumplimiento de la deriva en edificaciones de concreto reforzado mediante Redes Neuronales Artificiales/Optimization of beam and column sections for compliance drift of reinforced concrete buildings using Artificial Neural Networks—ProQuest*. <http://search.proquest.com/openview/8444a3a0dee1841dc855f438313534d6/1?pq-origsite=gscholar&cbl=1806363>
- Bitaraf, M., Hurlebaus, S., & Barroso, L. R. (2012). Active and semi-active adaptive control for undamaged and damaged building structures under seismic load. *Computer-Aided Civil and Infrastructure Engineering*, 27(1), 48–64. <https://doi.org/10.1111/j.1467-8667.2011.00719.x>

- Bojórquez, J., Tolentino, D., Yunes, J. T., & Ruiz, S. E. (2014). Diseño de edificios de concreto reforzado utilizando redes neuronales artificiales. *Sociedad Mexicana de Ingeniería Estructural*.  
[http://www.smie.org.mx/SMIE\\_Articulos/co/co\\_18/te\\_01/ar\\_09.pdf](http://www.smie.org.mx/SMIE_Articulos/co/co_18/te_01/ar_09.pdf)
- Brío, B. M. del, & Molina, A. S. (2001). *Redes neuronales y sistemas borrosos: Introducción, teoría y práctica / Bonifacio Martín del Brio, Alfredo Sanz Molina*.  
<https://dialnet.unirioja.es/servlet/libro?codigo=374757>
- CESDM. (2020). *Center for Engineering Strong Data Motion*.  
<https://strongmotioncenter.org/>
- Chauvin, Y., & Rumelhart, D. E. (1995). *Backpropagation: Theory, architectures, and applications*. Psychology Press.
- Chopra, A. K. (2001). *Dynamics of structures: Theory and applications to earthquake engineering*. CERN Document Server. <http://cds.cern.ch/record/576252>
- Clough, R. W., & Penzien, J. (1975). *Dynamics of structures*.  
<https://trid.trb.org/view.aspx?id=50306>
- Connor, J. J., & Faraji, S. (2016). *Fundamentals of structural engineering*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-24331-3>
- Dayhoff, J. E., & DeLeo, J. M. (2001). Artificial neural networks. *Cancer*, 91(S8), 1615–1635. [https://doi.org/10.1002/1097-0142\(20010415\)91:8+<1615::AID-CNCR1175>3.0.CO;2-L](https://doi.org/10.1002/1097-0142(20010415)91:8+<1615::AID-CNCR1175>3.0.CO;2-L)
- Demuth, H. B., Beale, M. H., De Jess, O., & Hagan, M. T. (2014). *Neural network design* (2nd ed.). Martin Hagan.

- Dyke, S. J., Jr, B. F. S., Sain, M. K., & Carlson, J. D. (1996). Modeling and control of magnetorheological dampers for seismic response reduction. *Smart Materials and Structures*, 5(5), 565. <https://doi.org/10.1088/0964-1726/5/5/006>
- Eberhart, R., & Kennedy, J. (1995). A new optimizer using particle swarm theory. , *Proceedings of the Sixth International Symposium on Micro Machine and Human Science, 1995. MHS '95*, 39–43. <https://doi.org/10.1109/MHS.1995.494215>
- Ertel, W. (2017). *Introduction to artificial intelligence*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-58487-4>
- Fisco, N. R., & Adeli, H. (2011a). Smart structures: Part I—Active and semi-active control. *Scientia Iranica*, 18(3), 275–284. <https://doi.org/10.1016/j.scient.2011.05.034>
- Fisco, N. R., & Adeli, H. (2011b). Smart structures: Part II — Hybrid control systems and control strategies. *Scientia Iranica*, 18(3), 285–295. <https://doi.org/10.1016/j.scient.2011.05.035>
- García, L. E. (1998). *Dinámica estructural aplicada al diseño sísmico*. (Universidad de Los Andes).
- Garrido, H., Curadelli, O., & Ambrosini, D. (2016). Experimental and theoretical study of semi-active friction tendons. *Mechatronics*, 39, 63–76. <https://doi.org/10.1016/j.mechatronics.2016.08.005>
- Gavin, H. P. (1998). Design method for high-force electrorheological dampers. *Smart Materials and Structures*, 7(5), 664. <https://doi.org/10.1088/0964-1726/7/5/010>
- Guzmán, A. F., Cardozo, A. O., & Ceresuela, D. (2017). Adaptive semi-active fuzzy control for steel frame buildings subjected to seismic excitation. *Prohitech '17*, 12. <https://www.buildup.eu/en/events/3rd-international-conference-protection-historical-constructions-prohitech17-0>

- Herráiz, M. (1997). *Conceptos básicos de sismología para ingenieros*. (Universidad Nacional de Ingeniería-CISMID, Vol. 1). CISMID.
- Hrovat, D., Barak, P., & Rabins, M. (1983). Semi-active versus passive or active tuned mass dampers for structural control. *Journal of Engineering Mechanics*, 109(3), 691–705. [https://doi.org/10.1061/\(ASCE\)0733-9399\(1983\)109:3\(691\)](https://doi.org/10.1061/(ASCE)0733-9399(1983)109:3(691))
- Hu, H. (2012). *Response control of seismically excited buildings: Application of viscous damping and negative stiffness control algorithm* [Master of Science, Purdue University]. Huan Hu.pdf. <https://engineering.purdue.edu/IISL/Publications/MS%20theses/Huan%20Hu.pdf>
- Jung, H.-J., Choi, K.-M., Spencer, B. F., & Lee, I.-W. (2006). Application of some semi-active control algorithms to a smart base-isolated building employing MR dampers. *Structural Control and Health Monitoring*, 13(2–3), 693–704. <https://doi.org/10.1002/stc.106>
- Kubat, M. (2017). *An introduction to machine learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-63913-0>
- Li, H., & Huo, L. (2010). Advances in structural control in civil engineering in china. *Mathematical Problems in Engineering*, 2010, e936081. <https://doi.org/10.1155/2010/936081>
- Li, Y. G., Fan, F., & Hong, H. P. (2015). Influence of number of records and scaling on the statistics of seismic demand for lattice structure. *Thin-Walled Structures*, 87, 115–126. <https://doi.org/10.1016/j.tws.2014.11.002>
- Lin, C.-C., Lu, L.-Y., Lin, G.-L., & Yang, T.-W. (2010). Vibration control of seismic structures using semi-active friction multiple tuned mass dampers. *Engineering Structures*, 32(10), 3404–3417. <https://doi.org/10.1016/j.engstruct.2010.07.014>

- Lu, L.-Y. (2004). Semi-active modal control for seismic structures with variable friction dampers. *Engineering Structures*, 26(4), 437–454.  
<https://doi.org/10.1016/j.engstruct.2003.10.012>
- Mazurowski, M. A., Habas, P. A., Zurada, J. M., Lo, J. Y., Baker, J. A., & Tourassi, G. D. (2008). Training neural network classifiers for medical decision making: The effects of imbalanced datasets on classification performance. *Neural Networks*, 21(2–3), 427–436. <https://doi.org/10.1016/j.neunet.2007.12.031>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.  
<https://doi.org/10.1007/BF02478259>
- Mitu et al. (2015). *Passive and semi-active bracing systems for seismic protection: A comparative study* - ProQuest.  
<http://search.proquest.com/openview/44b3c8fa7f80d23bd365397b53b47232/1?pq-origsite=gscholar&cbl=286206>
- Montgomery, D. (2004). *Diseño y análisis de experimentos*. (2da edición.). Limusa Wiley.
- Mori, T., Nilkhamhang, I., & Sano, A. (2007). Adaptive semi-active control of suspension system with MR damper. *IFAC Proceedings Volumes*, 40(13), 191–196.  
<https://doi.org/10.3182/20070829-3-RU-4911.00031>
- Moroni, G. (2014). La resistencia sísmica en el diseño contemporáneo: Reflexión sobre la influencia de las condiciones sísmicas en la arquitectura. *Revista A+ C*, 5(5).  
<http://www.revistas.usach.cl/ojs/index.php/amasc/article/view/1630>
- Ou, J., & Li, H. (2009). Design approaches for active, semi-active and passive control systems based on analysis of characteristics of active control force. *Earthquake*



- Engineering and Engineering Vibration*, 8(4), 493–506.  
<https://doi.org/10.1007/s11803-009-9119-z>
- Ozyildirim, B. M., & Avci, M. (2013). Generalized classifier neural network. *Neural Networks*, 39, 18–26. <https://doi.org/10.1016/j.neunet.2012.12.001>
- Pardo-Varela, J., & de la Llera, J. C. (2015). A Semi-active piezoelectric friction damper. *Earthquake Engineering & Structural Dynamics*, 44(3), 333–354.  
<https://doi.org/10.1002/eqe.2469>
- Paz, M., & Kim, Y. H. (2019). *Structural dynamics: Theory and computation*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-94743-3>
- Pérez, C. A. G., & González, J. V. (2008). Aplicación de un modelo de redes neuronales en la identificación del daño estructural en un puente vehicular. *CIENCIA ergo-sum*, 15(2), 176–188.
- Pnevmatikos, N. G., & Gantes, C. J. (2010). Design and control algorithm for structures equipped with active variable stiffness devices. *Structural Control and Health Monitoring*, 17(6), 591–613. <https://doi.org/10.1002/stc.334>
- Pnevmatikos, N. G., Kallivokas, L. F., & Gantes, C. J. (2004). Feed-forward control of active variable stiffness systems for mitigating seismic hazard in structures. *Engineering Structures*, 26(4), 471–483.  
<https://doi.org/10.1016/j.engstruct.2003.11.003>
- Qu, J., & Li, H. (2012). Optimal placement of passive energy dissipation devices by genetic algorithms. *Mathematical Problems in Engineering*, 2012, e474282.  
<https://doi.org/10.1155/2012/474282>

- Rai et al. (2009). *Seismic response control systems for structures*.  
<http://search.proquest.com/openview/2a2a8ef24de77f03ab84a823607dcf4f/1?pq-origsite=gscholar&cbl=2028808>
- Rubio-Hervas, J., Zao, D., & Reyhanoglu, M. (2015). *Nonlinear feedback control of self-sustained thermoacoustic oscillations*. ResearchGate.  
<http://dx.doi.org/10.1016/j.ast.2014.12.026>
- Salem, M. (2014). *Seismic response control of structures using semi-active and passive variable stiffness devices* [Doctor of Philosophy in Civil and Environmental Engineering, University of Nevada]. Seismic Response Control Of Structures Using Semi-Active and Passive.
- Sathyanarayana, S. (2014). A gentle introduction to backpropagation. *Numeric Insight, Inc.*, 15.
- SGC. (2020). *Servicio Geológico Colombiano*. <http://www.sgc.gov.co/>
- Singh, M. P., & Moreschi, L. M. (2002). Optimal placement of dampers for passive response control. *Earthquake Engineering & Structural Dynamics*, 31(4), 955–976.  
<https://doi.org/10.1002/eqe.132>
- Skansi, S. (2018). *Introduction to deep learning: From logical calculus to artificial intelligence*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-73004-2>
- Specht, D. F. (1990). Probabilistic neural networks. *Neural Networks*, 3(1), 109–118.  
[https://doi.org/10.1016/0893-6080\(90\)90049-Q](https://doi.org/10.1016/0893-6080(90)90049-Q)
- Symans, M. D. (2008). *Chapter 1 – Part A Dynamic loads, degrees of freedom, newton and D'Alembert methods for deriving SDOF EOM* [Notas del clase]. Structural dynamics, Rensselaer Polytechnic Institute RPI.

- Symans, M. D., & Constantinou, M. C. (1999). Semi-active control systems for seismic protection of structures: A state-of-the-art review. *Engineering Structures*, 21(6), 469–487. [https://doi.org/10.1016/S0141-0296\(97\)00225-3](https://doi.org/10.1016/S0141-0296(97)00225-3)
- USGS. (2020). *United States Geological Service*. <https://www.usgs.gov/>
- Winthrop, M. F. (2004). *Engineering tools for variable stiffness vibration suppression and isolation*.
- Ying, Z. G., Ni, Y. Q., & Ko, J. M. (2005). Semi-active optimal control of linearized systems with multi-degree of freedom and application. *Journal of Sound and Vibration*, 279(1–2), 373–388. <https://doi.org/10.1016/j.jsv.2003.11.004>

## 12. ANEXOS

A continuación, se presenta un listado de todos los archivos utilizados para obtener los resultados de esta tesis. Además, se incluye un código *quick response QR* (Fig. 90) para acceder fácilmente a todos los anexos.



Fig. 90: Código QR para anexos. Fuente: Elaboración propia.

Para los archivos que se utilizan en el software *Matlab*, se debe eliminar la numeración y el espacio que precede al nombre del archivo, para que se llame tal y como se muestra en el listado.

### 12.1. Anexos de algoritmos en *Matlab*

Anexo 1: “*TesisMaestriaMACR.m*”

Es el código del algoritmo en *Matlab* que realiza la interacción entre los algoritmos que realizan los procedimientos de las fases 1, 2 y 3.

Anexo 2: “*AnalisisDeFrecuencias.m*”

Es el código del algoritmo en *Matlab* que realiza los procedimientos de la fase 1.

Anexo 3: “*AnalisisMatricial.m*”

Es el código del algoritmo en *Matlab* que realiza los procedimientos de la fase 2.

Anexo 4: “*RNA.m*”

Es el código del algoritmo en *Matlab* que realiza los procedimientos de la fase 3.

Anexo 5: “*AproxRiost.m*”

Es el código del algoritmo en *Matlab* que calcula qué área de sección transversal de PTE comercial existente es más cercana al área de sección transversal predicha por la RNA.

Anexo 6: “*CodifRiost.m*”

Es el código del algoritmo en *Matlab* que determina el código de la configuración de riostras a partir de la existencia de riostras en la estructura.

Anexo 7: “*CreacionVarRiostras.m*”

Es el código del algoritmo en *Matlab* que crea las variables de riostra por cada piso a partir del vector de riostras de la estructura.

Anexo 8: “*CreacionVectRiostras.m*”

Es el código del algoritmo en *Matlab* que crea el vector de riostras de la estructura a partir de las variables de riostra por cada piso.

Anexo 9: “*DescodifRiost.m*”

Es el código del algoritmo en *Matlab* que determina la configuración de riostras en la estructura a partir del código de la configuración de riostras.

Anexo 10: “*LecturaDatosPerfiles.m*”

Es el código del algoritmo en *Matlab* que muestra las características de área de sección transversal e inercia para las secciones de columnas, vigas y riostras seleccionadas.

Anexo 11: “*LecturaSeccionesPerfiles.m*”

Es el código del algoritmo en *Matlab* que muestra las secciones de columnas, vigas y riostras a partir del área de sección transversal e inercia seleccionadas.

## **12.2. Anexos de archivos de datos para algoritmos en *Matlab***

Anexo 12: “*AceleracionSismoBerkeley.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Berkeley, EE.UU.

Anexo 13: “*AceleracionSismoCerroPrieto.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Cerro Prieto, México.

Anexo 14: “*AceleracionSismoGreenVille.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Green Ville, EE.UU.

Anexo 15: “*AceleracionSismoManabi.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Manabí, Ecuador.

Anexo 16: “*AceleracionSismoLosSantos.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Los Santos, Colombia.

Anexo 17: “*AceleracionSismoTijuana.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de Tijuana, México.

Anexo 18: “*AceleracionSismoElCentro.txt*”

Es el archivo de texto para *Matlab* que contiene la información del registro del acelerograma para el sismo de El Centro, EE.UU.

Anexo 19: “*KOBE.mat*”

Es el archivo de datos para *Matlab* que contiene el registro del acelerograma para el sismo de Kobe, Japón.

Anexo 20: “*NORTHRDG.mat*”

Es el archivo de datos para *Matlab* que contiene el registro del acelerograma para el sismo de Northridge, EE.UU.

Anexo 21: “*BaseDatos.mat*”

Es el archivo de datos para *Matlab* que contiene la base de datos de todas las estructuras analizadas con sus respectivas variables de interés para el funcionamiento de la RNA.

Anexo 22: “*DatosPerfEstr.txt*”

Es el archivo de texto para *Matlab* que contiene la información de área transversal e inercia para las secciones estructurales en estudio.

Anexo 23: “*ListaCodigR.mat*”

Es el archivo de datos para *Matlab* que contiene la lista de los códigos de configuraciones de riostras con su respectiva configuración.

Anexo 24: “*ListaPerfEstr.txt*”

Es el archivo de texto para *Matlab* que contiene los nombres de las secciones estructurales en estudio.

Anexo 25: “*RNA\_Entr1.mat*”

Es el archivo de datos para *Matlab* que contiene la información del entrenamiento la 1 RNA usada.

Anexo 26: “*RNA\_Entr10*”

Es el archivo de datos para *Matlab* que contiene la información del entrenamiento la 10 RNA usada.

### **12.3. Anexos de archivos de registros sísmicos**

Anexo 27: “*NP01755.V2*”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Berkeley, EE.UU.

Anexo 28: “*NP05053.RAW*”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Cierro Prieto, México.

Anexo 29: “*NCL001.txt*”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Green Ville, EE.UU.

Anexo 30: “2016-04-20160416235825\_CTUM2.anc”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Manabí, Ecuador.

Anexo 31: “2015-03-20150310205544\_CGIR2.anc”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Los Santos, Colombia.

Anexo 32: “CIDZA.V2”

Es el archivo de texto original que contiene los datos del registro del acelerograma para el sismo de Tijuana, México.

#### **12.4. Anexos de archivos de datos de resultados**

Anexo 33: “h200302 MIC MACR Secciones elementos.xlsx”

Es el archivo de datos que contiene información de las secciones de elementos estructurales en estudio con sus respectivos valores de área de sección transversal e inercia.

Anexo 34: “h200506 MIC MACR Base de datos RNA DisExp.xlsx”

Es el archivo de datos que contiene información del diseño de experimento para la base de datos para la RNA.

Anexo 35: “h200520 MIC MACR CritDecis RNA.xlsx”

Es el archivo de datos que contiene información de los criterios de decisión para determinar la configuración de la RNA a utilizar.

Anexo 36: “h200528 MIC MACR Revisión RNA.xlsx”

Es el archivo de datos que contiene información de la revisión de las predicciones de la RNA utilizada.